

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

**ANALIZA UTJECAJA PREDSEDNIČKIH
IZBORA U SAD-U U 2016. GODINI NA
TRŽIŠTE KAPITALA**

Mentor:

Izv.prof.dr.sc. Branka Marasović

Student:

Vladimir Štimac

Split, ožujak 2018.

SADRŽAJ

1. UVOD.....	4
1.1. Problem istraživanja.....	4
1.2. Predmet istraživanja.....	6
1.3. Hipoteze istraživanja	7
1.4. Ciljevi istraživanja	8
1.5. Metode istraživanja	8
1.6. Doprinos istraživanja	9
1.7. Struktura diplomskog rada.....	10
2. MARKOWITZEV MODEL OPTIMIZACIJE PORTFELJA	11
2.1. Temeljne odrednice Markowitzevog modela	11
2.1.1. Prinos portfelja	13
2.1.2. Očekivana vrijednost prinosa portfelja.....	15
2.1.3. Varijanca prinosa portfelja	16
2.1.4. Funkcija korisnosti	18
2.2. Efikasna granica.....	22
2.3. Doprinosi i kritike moderne teorije portfelja.....	26
2.4. Rizičnost vrijednosti	29
2.5. Beta – mjera sustavnog rizika.....	33
3. WALL STREET I PREDSJEDNIČKI IZBORI U SAD-U	35
3.1. Američko tržište kapitala.....	35
3.1.1. Temeljne odrednice Wall Street-a	40
3.1.2. Indeksi Wall Street-a	42

3.2. Predsjednički izbori u SAD-u u 2016. godini	45
3.2.1. Predizborne kampanje	45
3.2.2. Utjecaj predsjedničkih izbora na američko tržište kapitala	49
3.2.3. Utjecaj predsjedničkih izbora na ostala svjetska tržišta kapitala.....	54
4. FORMIRANJE PORTFELJA NA TRŽIŠTU KAPITALA	55
4.1. Dionice u sastavu portfelja.....	55
4.2. Izračun mjera rizika za promatrane dionice	58
4.3. Efikasna granica u razdoblju prije predsjedničkih izbora u SAD-u.....	63
4.4. Efikasna granica u razdoblju nakon predsjedničkih izbora u SAD-u ...	67
4.5. Usporedba dobivenih rezultata	70
5. ZAKLJUČAK.....	72
SAŽETAK.....	74
SUMMARY	75
POPIS LITERATURE	76
Knjige	76
Znanstvene publikacije.....	77
Internet izvori.....	78
POPIS SLIKA	80
POPIS TABLICA.....	81

1. UVOD

1.1. Problem istraživanja

Sjedinjene Američke države, od svih razvijenih država, imaju najširi raspon financijskih usluga i tržišta koji su na raspolaganju investitorima. Razvijenost financijskog tržišta odražava veličinu domaćeg gospodarstva, značenje u svjetskoj ekonomiji i političku predanost kapitalizmu (Foley, 1991.).

Tržište kapitala u Sjedinjenim Američkim Državama često poistovjećujemo s izrazom „Wall Street“. Wall Street je ulica u New Yorku u kojoj se nalaze dvije najveće svjetske burze po tržišnoj kapitaliziranosti. To su New York Stock Exchange, najveća i najznačajnija burza na svijetu, i NASDAQ Stock Market, druga najveća svjetska burza. Wall Street, dakle, predstavlja središte svjetske trgovine kapitalom pružajući investitorima izbor između oko 5200 dionica javnih poduzeća koje kotiraju na ovim burzama. Kapitaliziranost ovih tržišta na kraju 2016. godine iznosila je 28,1 trilijun američkih dolara od čega 20,2 trilijuna pripada New York Stock Exchange-u (Doidge, Kahle, Karolyi, Stulz, 2018., str. 17).

Nestabilnost na Wall Street-u djeluje kao domino efekt na sva svjetska tržišta. Značaj poduzeća koje kotiraju na američkom tržištu kapitala i velik broj transakcija na dnevnoj bazi razlozi su zbog kojih ostala svjetska tržišta s posebnom pozornošću prate događanja na Wall Street-u. Veličina tržišta i njezin značaj za svjetsku ekonomiju osigurava Sjedinjenim Američkim Državama poziciju predvodnice globalne ekonomije. Utjecaj globalizacije posebno se osjeća na svjetskim tržištima kapitala jer zbog globalne ekonomske i gospodarske povezanosti niti jedno tržište kapitala ne može u potpunosti anulirati događanja na ostalim značajnim tržištima, a to se posebno odnosi na značajne događaje u Sjedinjenim Američkim Državama.

Predsjednički izbori, dakako, spadaju među takve događaje jer Sjedinjene Američke Države imaju predsjednički sustav u kojem je predsjednik na čelu izvršne vlasti. Predsjednik države također je predsjednik vlade (personalna unija). S obzirom na veličinu i značaj američkog gospodarstva te državno uređenje očigledno je zašto predsjednički izbori imaju toliki utjecaj na globalnu ekonomiju te posebno na svjetska tržišta kapitala.

Američki predsjednički izbori u 2016. godini bili su jedni od najneizvjesnijih ikada te su se njihovi rezultati odrazili na burze diljem svijeta. U trenucima kada je postalo jasno da će novi predsjednik SAD-a postati republikanac Donald Trump, a ne demokratkinja Hillary Clinton kako su ankete predviđale, globalna financijska tržišta su doživjela potres.

Na Wall Street-u su sva tri glavna indeksa dionica pala za 4 posto ili više. Japanski Nikkei indeks pao je preko 5 posto, a indeks burze u Hong Kongu za 2,8 posto (Denyer, Mui, 2016.).

Kako bi se utvrdio utjecaj koji je izbor Donalda Trumpa za predsjednika Sjedinjenih Američkih Država imao na američko tržište kapitala te koje su posljedice s kojima se investitori moraju nositi u pogledu prinosa i rizika portfelja koristit će se moderna teorija portfelja.

Moderna teorija portfelja jedna je od najpoznatijih teorija pronalaženja optimalnog portfelja vrijednosnih papira čije temelje postavlja Harry Max Markowitz 1952. godine te je za svoja dostignuća u razvoju ove teorije 1990. godine dobio Nobelovu nagradu iz ekonomije.

Osnovna Markowitzeva ideja bila je pronaći ravnotežu između rizika i prinosa što danas nazivamo Model prosjek-varijanca (MV model). Tim modelom moguće je, uz pretpostavku dostupnosti svih potrebnih informacija, formirati portfelj koji na određenom stupnju rizika donosi najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalni rizik (Jerončić, Aljinović, 2011., str. 585).

Dakle, Markowitz je razvio model koji diversifikacijom portfelja uspješno reducira ukupni rizik. Dokazao je da se rizik i prinos mogu uravnotežiti u dobro odabranoj kombinaciji vrijednosnica te je ovaj način optimizacije portfelja u potpunosti zamijenio dotadašnji pristup koji se temeljio na maksimizaciji očekivanog prinosa što je za investitore predstavljalo vrlo rizično ulaganje.

Markowitzev model formira se na način da se postavi donja granica prinosa portfelja i tada se iz skupa mogućih portfelja izabere onaj koji ima minimalan rizik ili se postavi gornja granica prihvatljivog rizika te se tada izabere portfelj koji uz zadani rizik nosi najveći prinos (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 13).

Markowitzev model koristit će se u ovom diplomskom radu kako bi se utvrdio odnos prinosa i rizika prije predsjedničkih izbora u SAD-u te odnos prinosa i rizika nakon neočekivane pobjede republikanskog kandidata Donalda Trumpa.

1.2. Predmet istraživanja

Predmet ovog istraživanja je korištenje Markowitzevog modela optimizacije portfelja u svrhu formiranja efikasne granice na američkom tržištu kapitala u dva promatrana razdoblja, razdoblju prije predsjedničkih izbora u SAD-u u 2016. godini te razdoblju nakon odluke njezinih državljana o novom predsjedniku Sjedinjenih Američkih Država. U ovom diplomskom radu prikazat će se i objasniti posljedice koje je takva odluka imala prvenstveno na američko tržište, ali i na ostala svjetska tržišta kapitala.

Sjedinjene Američke Države najznačajnija su svjetska ekonomska velesila te, pod utjecajem globalizacije, svaki značajniji događaj u ovoj državi predstavlja značajni događaj za cijeli svijet. Upravo iz tih razloga neočekivana pobjeda Donalda Trumpa na američkim predsjedničkim izborima u 2016. godini rezultirala je velikim potresima na svjetskim tržištima kapitala.

Predizborna obećanja republikanskog kandidata bila su usmjerena protiv većine međunarodnih sporazuma SAD-a te je njegova pobjeda izazvala uzbunu na svim svjetskim tržištima kapitala, a najviše se to odnosi na velike svjetske gospodarske sile kojima je značajan udio u ukupnoj trgovini upravo trgovina sa Sjedinjenim Američkim Državama.

Ovim istraživanjem želi se kroz primjenu moderne teorije portfelja u dva različita razdoblja analizirati utjecaj rezultata predsjedničkih izbora na američko tržište kapitala. Analiza utjecaja bazirat će se na izračunu rizika dionica s Wall Street-a pomoću različitih mjera rizika kao što su varijanca, beta i rizičnost vrijednosti (VaR), na procjenu očekivanih prinosa odabranih dionica te na procjenu efikasne granice prije i nakon predsjedničkih izbora. Također će se teorijski prikazati posljedice koje su negativno odrazile na ostala svjetska tržišta kapitala.

1.3. Hipoteze istraživanja

Na temelju postavljenog problema i predmeta istraživanja definiraju se istraživačke hipoteze. Postavljene hipoteze će se kroz empirijski dio rada testirati s ciljem njihova prihvatanja ili odbacivanja.

Radne hipoteze:

H1- Prinos koji portfelj nosi investitoru na američkom tržištu kapitala, uz zadanu stopu rizika, značajno raste nakon izbora Donalda Trumpa za predsjednika SAD-a.

Navedenom hipotezom istražiti će se utjecaj rezultata američkih predsjedničkih izbora na prinos koji ostvaruje investitor na američkoj burzi. Hipoteza će se istražiti izračunom efikasnih granica u razdoblju prije i poslije izbora za predsjednika SAD-a.

H2- Rizik dionica s američkog tržišta kapitala značajno pada nakon izbora Donalda Trumpa za predsjednika SAD-a.

Navedenom hipotezom istražiti će se smanjenje rizika na američkom tržištu kapitala nakon predsjedničkih izbora u SAD-u u 2016. godini. Hipoteza će se prihvatiti ili odbaciti korištenjem mjera rizika poput bete, varijance te rizičnosti vrijednosti (VaR).

H3- Odluka američkih građana o novom predsjedniku SAD-a negativno je utjecala na ostala svjetska tržišta kapitala.

Nestabilnost na svjetskim tržištima pojavila se nakon predsjedničkih izbora u SAD-u zbog predizbornih obećanja Donalda Trumpa koje su uključivali raskid trgovinskih sporazuma s drugim zemljama među kojima su gospodarske velesile poput Kine, Japana, Južne Koreje te Europske Unije čije gospodarstvo značajno ovisi o suradnji sa SAD-om. Ovom hipotezom istražiti će se postoji li negativan utjecaj izbora novog američkog predsjednika na značajna svjetska tržišta kapitala.

1.4. Ciljevi istraživanja

Ciljevi istraživanja proizlaze iz navedenog problema i predmeta istraživanja te se odnose na ispitivanje postavljenih hipoteza istraživanja.

Osnovni cilj ovog istraživanja je utvrditi koje je posljedice izbor Donalda Trumpa za predsjednika SAD-a izazvao na američkom tržištu kapitala. Spomenute posljedice podrazumijevaju promjenu odnosa prinosa i rizika portfelja nakon iznenađujuće pobjede republikanskog kandidata koju je tržište dočekalo potpuno nespremno. Svrha ovog rada je bolje razumijevanje pozicije investitora na američkom tržištu kapitala te načina na koji će se ova odluka američkih građana odraziti na prinos njihovih investicija.

Također je cilj ovog istraživanja prikazati utjecaj ovog događaja na ostala svjetska tržišta kapitala čija pozicija, izravno ili neizravno, ovisi o politici SAD-a.

1.5. Metode istraživanja

Prilikom izrade diplomskoga rada, u svrhu dokazivanja ili opovrgavanja zadanih hipoteza, koristit će se istraživačke metode: metoda analize, metoda sinteze, metoda komparacije, metoda indukcije i metoda dedukcije. Od matematičkih metoda koristit će se metode matematičkog programiranja te matričnog računa.

Metoda analize je postupak znanstvenog istraživanja i objašnjavanja putem raščlanjivanja složenih tvorevina na njihove jednostavnije sastavne dijelove, te izučavanje svakog dijela samog za sebe i u odnosu na druge dijelove, odnosno cjeline.

Metoda sinteze je postupak znanstvenog istraživanja i objašnjavanja putem spajanja jednostavnih misaonih tvorevina u sve složenije, povezujući izdvojene elemente u jedinstvenu cjelinu u kojoj su njezini dijelovi uzajamno povezani.

Metoda komparacije predstavlja postupak uspoređivanja istih ili srodnih činjenica, pojava, procesa i odnosa, odnosno utvrđivanje njihove sličnosti i razlika u njihovom ponašanju i intenzitetu.

Metoda indukcije predstavlja primjenu induktivnog načina zaključivanja. Omogućuje da se na temelju pojedinačnih činjenica i saznanja dolazi do stvaranja zakonitosti, odnosno spoznaje novih činjenica i novih zakonitosti.

Metoda dedukcije nam omogućuje da se na temelju općih sudova, logičkih obilježja između samih pojmova, izvode pojedinačni sudovi, zaključci i tvrdnje, odnosno otkriju spoznaje, te dokažu nove činjenice, nove zakonitosti.

U empirijskom dijelu rada koristit će se tablični kalkulator MS Excela pomoću kojeg će se formirati efikasni portfelji i izračunati rizičnost vrijednosti i beta, te analizirati utjecaj rezultata predsjedničkih izbora u SAD-u na američko tržište kapitala.

1.6. Doprinos istraživanja

Otkada je Harry Max Markowitz 1952. godine postavio temelje moderne teorije portfelja, mnogi su stručnjaci istraživali Markowitzev model te su na temelju tog modela napisani mnogi radovi koji su rezultirali boljim razumijevanjem ove tematike.

Moderna teorija portfelja predmet je i ovog rada, no u ovom slučaju koristit će se u svrhu boljeg razumijevanja aktualne teme koja se odnosi na neočekivani izbor republikanskog kandidata Donalda Trumpa za novog predsjednika Sjedinjenih Američkih Država. Doprinos istraživanja odnosi se na utvrđivanje utjecaja koji je izbor novog predsjednika SAD-a imao na američko tržište kapitala. Usporedbom odnosa prinosa i rizika portfelja prije i nakon predsjedničkih izbora u SAD-u analizirat će se utjecaj ovog događaja na američko tržište te prikazati posljedice s kojima se suočavaju investitori na ostalim svjetski značajnim tržištima kapitala.

1.7. Struktura diplomskog rada

Diplomski rad se sastoji od 5 poglavlja.

U uvodnom dijelu rada utvrđuju se problem i predmet istraživanja te se definiraju istraživačke hipoteze koje će se kasnije kroz istraživanje prihvatiti ili odbaciti. Također se postavljaju ciljevi ovog istraživanja, objašnjavaju metode istraživanja i doprinos koji će ovaj rad imati.

Nakon uvodnog dijela definirat će se Markowitzev model optimizacije portfelja. U tom drugom poglavlju prikazat će se teorijske i matematičke odrednice ovog modela te utvrditi način formiranja optimalnog portfelja. Uz Markowitzev model objasniti će se pojam rizičnosti vrijednosti i mjera sustavnog rizika.

Treće poglavlje odnosi se na prikaz funkcioniranja američkog tržišta kapitala te upoznavanje s aktualnom tematikom koja se razrađuje u ovom radu, a to su predsjednički izbori u SAD-u u 2016. godini. Također će se objasniti njihov utjecaj na američko i ostala svjetska tržišta kapitala.

U četvrtom poglavlju formirat će se dionički portfelj te će se prikazati odnosi prinosa i rizika tog portfelja prije izbora Donalda Trumpa za predsjednika SAD-a te odnosi prinosa i rizika nakon navedenog izbora. U svrhu boljeg razumijevanja posljedica ovih predsjedničkih izbora usporedit će se dobiveni rezultati u dva vremenska razdoblja.

Na kraju diplomskog rada donijet će se zaključak na temelju provedenog istraživanja koji će prihvatiti ili odbaciti postavljene istraživačke hipoteze.

2. MARKOWITZEV MODEL OPTIMIZACIJE PORTFELJA

2.1. Temeljne odrednice Markowitzevog modela

Investicije su odigrale ključnu ulogu u usponu kapitalizma i svijeta kakvog danas poznajemo. Ogromna količina investicija koja danas prožima tržišta svih država te pokreće svjetski ekonomski sustav zaslužna je za napredak čovječanstva u svim područjima. Zahvaljujući globalizaciji velika većina informacija je dostupna svima stoga su malobrojni ljudi kojima je pojam optimizacije portfelja nepoznat. Upravo je Harry Max Markovitz postavio temelje suvremenog investiranja svojim modelom optimizacije portfelja. Njegov rad „Portfolio Selection“, objavljen u ožujku 1952. godine u prestižnom financijskom časopisu „Journal of Finance“, temelj je moderne teorije portfelja te je napravio revoluciju u poimanju učinkovitosti portfelja te načinu odabira dionica koje sačinjavaju određeni portfelj. Za svoj doprinos u razvoju moderne teorije portfelja, Markowitz je 1990. dobio Nobelovu nagradu iz ekonomije.

Dotadašnji pristup ulaganjima temeljio se na pronalasku kvalitetnih poduzeća za malu cijenu. To je najčešće značilo površnu fundamentalnu analizu poduzeća koja bi rezultirala vrlo rizičnim ulaganjima. Nitko nije obraćao pozornost na rizik koji se preuzima takvim načinom ulaganja osim tada 25-godišnjeg studenta koji u prvi plan stavlja odnos prinosa i rizika kao kriterij vrednovanja isplativosti ulaganja. Markowitzev model ukazuje nam na važnost diversifikacije portfelja što je u skladu s maksimom „nije dobro držati sva jaja u istoj košari“.

Markowitz je pionir u promatranju i definiranju korelacije različitih vrijednosnica čime je značajno utjecao na način analiziranja investitora, ali i na općenito promatranje svih događanja u ekonomiji. Dakle, osim dvije osnovne varijable, prinosa (r) i rizika (σ), koje utječu na odluku o formiranju pojedinog portfelja, Markowitz u svom modelu uključuje i novu, treću varijablu – međuovisnost kretanja pojedinačnih vrijednosnica koje se nalaze unutar portfelja, to jest njihovu korelaciju (ρ). Uvođenjem ove varijable investitori mogu formirati nove portfelje koji im omogućuju veće prinose uz isti rizik ili iste prinose uz manji rizik (Žiković, 2005., str.7).

Markowitzev model, koji je poznat i kao MV model (mean-variance model), omogućava investorima da maksimiziraju prinos pri određenoj stopi rizika ili minimiziraju rizik pri

određenoj stopi prinosa. Dakle, ukoliko je stopa rizika konstanta, moguće je formirati portfelj koji donosi najveću stopu prinosa. Također, ukoliko nam je poznata stopa prinosa, imamo mogućnost formirati portfelj s najnižom stopom rizika.

Osnovna pretpostavka MV modela je averzija investitora prema riziku što znači da će u slučaju izbora između dvije dionice s jednakim prinosom investitor uvijek izabrati manje rizičnu, odnosno dionicu s manjom stopom rizika. Portfelj koji za zadanu stopu rizika ima najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalni rizik Markowitz je nazvao efikasnim portfeljom (Aljinović, Marasović, Šego, 2011., str. 137).

Kod sastavljanja efikasnog portfelja ne smije se zanemariti značaj korelacije vrijednosnica koje čine spomenuti portfelj. Pozitivna korelacija je nepoželjna jer povećava rizik od gubitaka u slučaju tržišne nestabilnosti. Negativnom korelacijom se izbjegava rizik povećanja gubitaka jer se cijena vrijednosnica kreće u suprotnim smjerovima što znači da pozitivan prinos jedne vrijednosnice neutralizira negativan prinos druge vrijednosnice. Potrebno je i naglasiti da se diversifikacijom portfelja rizik ne može u potpunosti neutralizirati jer će sustavni rizik uvijek postojati, ali MV model nam omogućava formiranje portfelja s najmanjim mogućim rizikom u odnosu na željeni prinos.

Osnovne pretpostavke Markowitzevog modela (Aljinović, Jerončić, 2011., str. 585):

- prinosi na dionice su distribuirani po normalnoj distribuciji,
- investitori žele maksimizirati svoju ekonomsku korisnost,
- investitori su racionalni i imaju averziju prema riziku,
- investitori su dobro obaviješteni o svim relevantnim činjenicama potrebnima za
- donošenje investicijske odluke, nema transakcijskih i poreznih troškova,
- vrijednosnice su savršeno djeljive.

Također je pretpostavljeno da investitor ima slobodan izbor od N rizičnih vrijednosnica s poznatim očekivanim prinosom, varijancom i standardnom devijacijom, kao i matricom njihovih varijanci i kovarijanci (Aljinović, Jerončić, 2011., str. 585).

2.1.1. Prinos portfelja

Kod računanja prinosa portfelja pretpostavlja se da investitor može ulagati u n različitih vrijednosnih papira u trenutku $t=0$ i da ih posjeduje sve do trenutka $t=T$. U tom slučaju govorimo o statičkom modelu koji je neovisan o duljini trajanja vremenskog razdoblja. Pretpostavlja se također da nema transakcijskih troškova i da su vrijednosnice savršeno djeljive. Pretpostavka o beskonačnoj djeljivosti bolje je aproksimirana kod velikih portfelja institucionalnih investitora nego kod pojedinačnih investitora koji ima značajno manje portfelje (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 2).

Cijene vrijednosnice u trenutku $t=0$ i trenutku $t=T$ određuju prinos i -te vrijednosnice R_i , $i \in \{1, 2, \dots, n\}$, u trenutku $t=T$. Preciznije, ako je u trenutku $t \in \{0, T\}$ cijena vrijednosnog papira $P_i(0)$, odnosno $P_i(T)$, tada se složeni kontinuirani prinos pojedinog vrijednosnog papira računa izrazom (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 2):

$$R_i = \ln \left(\frac{P_i(T)}{P_i(0)} \right) \quad (1)$$

a diskretni prinos izrazom:

$$R_i = \frac{[P_i(T) - P_i(0)]}{P_i(0)} \quad (2)$$

Ukoliko je u promatranom vremenskom razdoblju isplaćena dividenda za promatranu dionicu, tada se ukupni prinos dionice računa tako da se brojnicima gornjih izraza doda isplaćena dividenda. Prinos izračunat kontinuiranim ukamaćivanjem uvijek je manji od prinosa izračunatog diskretnim ukamaćivanjem, ali razlika u rezultatu najčešće nije velika. Razlika u rezultatu prinosa izračunatog kontinuiranim ukamaćivanjem i diskretnim ukamaćivanjem nije toliko velika kada je riječ o dnevnim prinosima, a postaje izraženija za duža vremenska razdoblja. Složeni kontinuirani prinos je prikladnija mjera prinosa u odnosu na složeni diskretni prinos kada podatci o prinosima za periode iz prošlosti određuju distribuciju prinosa (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 3).

Nadalje oznaka π_i je dio početnog uloga x investiranog u vrijednosnicu i u trenutku $t=0$, to jest (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 3):

$$\pi_i = \frac{\psi_i P_i(0)}{x} \quad (3)$$

Gdje je ψ_i broj i -tih vrijednosnica kupljenih u trenutku $t=0$. Vektor $\pi = (\pi_1, \dots, \pi_n)'$ nazvat ćemo vektorom portfelja investitora. Nadalje vrijedi:

$$\sum_{i=1}^n \pi_i = 1 \quad (4)$$

O izboru vektora portfelja π na početku promatranog razdoblja ovisit će ukupni prinos ili prinos portfelja u trenutku $t=T$:

$$R^n = \frac{x^n(T) - x}{x} \quad (5)$$

Gdje su $X^n(T) = \sum_{i=1}^n \psi_i P_i(T)$ ukupna novčana sredstva dobivena prodajom dionica u trenutku $t=T$. -

U diskretnom slučaju prinosa portfelja vrijedi:

$$R^n = \sum_{i=1}^n \pi_i R_i.$$

Važno je spomenuti da u slučaju kratke prodaje π_i , $i \in \{1, 2, \dots, n\}$ poprima negativne vrijednosti. Kratka prodaja je oblik investiranja u kojoj investitor prodaje vrijednosnicu koja je posuđena od treće osobe (uglavnom od brokera) jer predviđa da će cijena te vrijednosnice pasti te će imati mogućnost otkupiti je po nižoj cijeni. Ovaj oblik je, dakle, suprotnost osnovnom pojmu investiranja koji se temelji na činjenici da je investitor u potrazi za vrijednosnicama koje može kupiti po nižoj cijeni kako bi ostvario određenu dobit kada njena vrijednost na tržištu poraste. Vlasnik tog vrijednosnog papira mora odobriti kratku prodaju i pritom u svakom trenutku znati da se dogodila transakcija kratke prodaje te tko je novi vlasnik vrijednosnice. Investitor će ostvariti pozitivan prinos od prodaje vrijednosnice ukoliko su investitorski troškovi na kraju transakcije manji od cijene po kojoj je na početku prodao vrijednosni papir.

Dakle, u situaciji kratke prodaje zarada se postiže smanjivanjem vrijednosti vrijednosnog papira na tržištu za razliku od standardnog kupovanja vrijednosnice po nižoj cijeni te ostvarivanje profita rastom njene cijene na tržištu.

2.1.2. Očekivana vrijednost prinosa portfelja

S obzirom da je cijena vrijednosnice u nekom budućem trenutku t slučajna varijabla $P_f(t)$ i prinos te iste vrijednosnice $R_f(t)$ je slučajna varijabla. Promatranjem vrijednosti prinosa koje imaju pojedini vrijednosni papiri u prošlosti možemo uočiti da oni slijede određenu distribuciju. Postavlja se pitanje kakvog će oblika biti funkcija distribucije prinosa portfelja ako su poznate funkcije distribucije prinosa pojedinačnih vrijednosnih papira (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 7)?

Markowitz je u svojim istraživanjima iznio pretpostavku da su distribucije prinosa portfelja i distribucije prinosa individualnih ulaganja približno normalne. Osnovu za izračunavanje vjerojatnosti određenog rezultata u nizu predstavlja normalna distribucija, a može se okarakterizirati poznajući njena dva pokazatelja: aritmetičku sredinu i standardnu devijaciju (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 7).

Očekivana vrijednost zbroja dviju slučajnih varijabli je jednaka zbroju očekivanih vrijednosti pojedine slučajne varijable, odnosno vrijedi $E(X+Y)=E(X)+E(Y)$. Također vrijedi da je očekivana vrijednost umnoška konstante i slučajne varijable jednaka umnošku konstante i očekivane vrijednosti slučajne varijable, to jest $E(\alpha X) = \alpha E(X)$. Iz navedenog slijedi:

$$\mu_\pi = E(R_n) = E(\sum_{i=1}^n \pi_i R_i) = \sum_{i=1}^n \pi_i E(R_i) = \sum_{i=1}^n \pi_i \mu_i \quad (6)$$

Stoga se zaključuje da je aritmetička sredina ili očekivana vrijednost prinosa portfelja koji se sastoji od n vrijednosnica vagana aritmetička sredina prinosa individualnih ulaganja, gdje su ponderi udjeli individualnih vrijednosnica u portfelju definirani relacijom (3) (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 7).

2.1.3. Varijanca prinosa portfelja

Pri ulaganju u pojedinu vrijednosnicu te formiranju određenog portfelja rizik predstavlja mogućnost da uložena sredstva ostvare manju dobit od očekivane ili ostvare gubitak. Rizik portfelja je, dakle, odstupanje stvarne vrijednosti od njezine srednje očekivane vrijednosti, odnosno mogućnost da se ne ostvari očekivani prinos na uložena sredstva. Rizik se mjeri varijancom i standardnom devijacijom.

Varijanca predstavlja sumu ponderiranih kvadrata odstupanja mogućih prinosa od očekivane srednje vrijednosti u kojoj pondere predstavljaju vjerojatnosti nastupa svakog pojedinog prinosa (Serdar, Šošić, 1994., str.61).

Markowitz rizik ulaganja u pojedinu vrijednosnicu kvantificira varijancom prinosa $Var(R_i)$ te se njegov model vodi pretpostavkom normalne distribucije prinosa dionica. U skladu s tom pretpostavkom dionice čija vrijednost više varira u odnosu na očekivanu vrijednost su rizičnije vrijednosnice, stoga varijanca predstavlja prikladnu mjeru rizika. Iznimno, u situaciji kada je varijanca $Var(R_i)=0$ možemo reći da je vrijednosnica bezrizična, u protivnom vrijednosnica sadrži rizik (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 8).

Rizik portfelja definiramo kao varijancu prinosa portfelja $Var(R^\pi)$ koja je definirana izrazom (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 8):

$$Var(R^\pi) = E\{[(R^\pi)^2] - [E(R^\pi)]^2\} \quad (7)$$

Korištenjem linearnosti matematičkog očekivanja, može se pokazati da je :

$$Var(R^\pi) = E[(R^\pi)^2] - [E(R^\pi)]^2 \quad (8)$$

Raščlanjivanjem ovog izraza i primjenom navedenih svojstava aditivnosti i multiplikativnosti očekivane vrijednosti slučajne varijable, dobiva se (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 9):

$$Var(R^\pi) = \sum_{i=1}^n \sum_{j=1}^n \pi_i \sigma_{ij} \pi_j \quad (9)$$

gdje je :

$Var(R^\pi)$ - rizik portfelja

π_i - vrijednosni udio i -te vrijednosnice u portfelju;

π_j - vrijednosni udio j -te vrijednosnice u portfelju;

σ_{ij} - kovarijanca vrijednosnica i i j

$$\sigma_{ij} = Cov(R_i, R_j) = E(R_i, R_j) - E(R_i)E(R_j) \quad i, j \in \{1, 2, \dots, n\}$$

Kovarijanca prinosa vrijednosnice same sa sobom $\sigma_{i,i}$ može se tretirati kao varijanca prinosa promatrane vrijednosnice (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 9):

$$Var(R_i) = E[(R_i)^2] - [E(R_i)]^2 = (R_i R_j) - E(R_i)E(R_j) = Cov(R_i, R_j) \quad (10)$$

Budući da je

$$\sum_{i=1}^n \sum_{j=1}^n \pi_i \pi_j = 1 \quad (11)$$

Možemo reći da jednakost (9) izražava $Var(R^\pi)$ kao vagani prosjek n^2 varijanci i kovarijanci prinosa vrijednosnica u portfelju.

Za razliku od očekivane vrijednosti prinosa portfelja koja je linearna funkcija udjela investicija u portfelju, varijanca prinosa portfelja nije linearna funkcija udjela investicija. Razlog tome je što se moguće varijance prinosa oko očekivanih vrijednosti svake investicije ne moraju podudarati niti intenzitetom niti smjerom kretanja. Zbog toga će varijanca prinosa portfelja ovisiti o udjelima pojedinih vrijednosnica u portfelju, varijancama prinosa navedenih vrijednosnica te korelaciji između prinosa tih vrijednosnica u portfelju (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 10). Težnja svakog investitora je smanjenje varijance prinosa portfelja njegovom diversifikacijom čime se maksimalno iskorištavaju prednosti korelacije te se reducira nesustavni rizik.

2.1.4. Funkcija korisnosti

Korisnost je subjektivna vrijednost za svakog pojedinca, odnosno varira od pojedinca do pojedinca ovisno o njegovim preferencijama. Različitu korisnost kod pojedinaca prepoznajemo kada osobe različito percipiraju vrijednost istog predmeta, odnosno što za nekoga ima veliku korisnost za drugu osobu nema značajnu korisnost.

Poznati švicarski fizičar Bernoulli je postulirao S oblik krivulje korisnosti, konkavnu funkciju ukupnog bogatstva donositelja odluke da bi objasnio zašto su ljudi općenito neskloni riziku, te voljni pristati na niže naknade u zamjenu za sigurnost. Pretpostavlja racionalnost donositelja odluke u smislu da će donositelj odluke uvijek izabrati onu inačicu koja mu donosi najveću korisnost (Kahneman, Tversky, 1979., str. 279).

Funkcija korisnosti određuje ponašanje investitora. Svi investitori imaju averziju prema nepotrebnom riziku i preferiraju sigurnost, te se s obzirom na preferenciju rizika razlikuju tri osnovna oblika funkcije korisnosti (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 9):

- ☐ Konkavna funkcija korisnosti; karakteristična za osobe koje izbjegavaju rizik (risk averse)
- ☐ Konveksna funkcija korisnosti; karakteristična za osobe koje su sklone riziku (riskseekers)
- ☐ Linearna funkcija korisnosti; karakteristična za osobe koje su indiferentne u odnosu na rizik tj. rukovode se jedino maksimalnim očekivanim prinosom (risk neutral)

Funkcija korisnosti $U(W)$ je rastući oblik te funkcije što znači da će investitor u svakom slučaju preferirati mogućnost u kojoj može ostvariti veći prinos u usporedbi s mogućnošću u kojoj će ostvariti manji prinos uz pretpostavku da su opcije jednako vjerojatne (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 8).


Oblik funkcije korisnosti odražava stav ulagača prema riziku. Osobe koje izbjegavaju rizik (risk-averse person) neće preuzeti rizik i investirati svoja sredstva u situaciji kada je vjerojatnost dobitka i gubitka jednaka odnosno 50:50, što možemo zapisati ovako (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 11):

$$U(W) > \frac{1}{2}U(W + G) + \frac{1}{2}U(W - G) \quad (12)$$

Pomnožimo li prethodni izraz s 2, dobivamo:

$$2U(W) - U(W - G) > U(W + G) - U(W) \quad (13)$$

Ovakva funkcija korisnosti je konkavna $U''(W) < 0$. Investitor koji izbjegava rizik smanjuje novčani udio svoje imovine investirane u rizični portfelj usporedno s povećanjem svojeg bogatstva i izgleda na sljedeći način:



Slika 1. Funkcija korisnosti investitora koji izbjegava rizik

Izvor: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str.11.

Osoba koja indiferentna na rizik (risk-neutral person) svejedno je hoće li investirati dio bogatstva ili ne u situaciji kada je vjerojatnost dobitka i gubitka jednaka odnosno 50:50, te za takvog investitora vrijedi (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 12):

$$U(W) = \frac{1}{2}U(W + G) + \frac{1}{2}U(W - G) \quad (14)$$

odnosno

$$U(W) - U(W - G) = U(W + G) - U(W) \quad (15)$$

U ovom slučaju funkcija korisnosti je linearna, to jest $U''(W)=0$.


Za osobe sklone riziku (risk-seeking person) vrijedi relacija:

$$U(W) < \frac{1}{2}U(W + G) + \frac{1}{2}U(W - G) \quad (16)$$

odnosno:

$$U(W) - U(W - G) < U(W + G) - U(W) \quad (17)$$

te je riječ o konveksnoj funkciji korisnosti, za koju vrijedi $U''(W)>0$. Ovaj investitor će povećati novčani udio svoje imovine investirane u rizični portfelj usporedno s povećanjem svoga bogatstva.



Slika 2. Funkcija korisnosti 3 vrste investitora prema sklonosti riziku

Izvor: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 12.

Funkciju korisnosti investitora koji ulaže na tržište kapitala možemo prikazati kao funkciju očekivanog prinosa portfelja. Očekivana vrijednost funkcije korisnosti tada ovisi o očekivanom prinosu portfelja i varijanci (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 12):


$$E(U) = E(U)(\mu_{\pi}, \sigma_{\pi}^2) \quad (18).$$

Kao što je već navedeno pretpostavka Markowitza jest da je funkcija korisnosti konkavna, odnosno da postoji određeni stupanj averzije prema riziku i da je funkcija kvadratna.

2.2. Efikasna granica

Portfelj je skup različitih kombinacija vrijednosnica, svaki portfelj nosi određenu razinu rizika te za preuzeti rizik određenu razinu prinosa. Adekvatan portfelj za svakog pojedinog investitora ovisi o njegovim preferencijama. Ukoliko je u interesu investitora ostvariti maksimalan profit, za njega će efikasan portfelj biti onaj koji nosi najveći prinos bez obzira na razinu rizika, a ukoliko je investitoru u cilju preuzeti minimalan rizik za njega će adekvatan biti onaj portfelj s minimalnom razinom rizika bez obzira na razinu prinosa koju može ostvariti. Pod pretpostavkom da je investitor racionalan možemo donijeti zaključak da će iz beskonačnog broja portfelja izabrati onaj koji je efikasan (Orlović, 2009., str. 6).

Portfelj se može prikazati točkom u koordinatnoj ravnini gdje apscisa predstavlja rizik, a ordinata stupanj očekivane stope prinosa. Skup svih točaka pridruženih mogućim portfeljima od n vrijednosnica prikazan je na slici 3 i naziva se skup mogućih portfelja. Lijeva granica skupa mogućih portfelja naziva se skup minimalne varijance (minimum-variance set). Njega sačinjavaju točke koje za danu stopu prinosa imaju najmanju varijancu.




Slika 3. Skup mogućih portfelja

Izvor: Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 139.

Markowitzeva osnovna ideja optimizacije portfelja bila je pronaći ravnotežu između rizika i prinosa portfelja. Njegov model optimizacije portfelja formira se na način da ulagač odredi donju granicu prinosa portfelja te se tada iz skupa mogućih portfelja izabere onaj koji ima minimalnu varijancu, odnosno minimalan rizik. Drugi pristup je da ulagač odredi gornju granicu prihvatljivog rizika i onda se iz mogućeg skupa portfelja izabere onaj koji maksimalizira prinos (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 13). Takav portfelj koji za zadanu stopu rizika ima najveću stopu prinosa, odnosno portfelj koji za zadanu stopu prinosa ima minimalan rizik, Markowitz je nazvao efikasnim portfeljem (Aljinović, Marasović, Šego, 2011., str. 137).

Efikasna granica je skup optimalnih portfelja koji imaju najveći mogući prinos za zadanu stopu rizika ili najmanju stopu rizika za određeni očekivani prinos. Budući da je njezin oblik zakrivljen, a ne linearan, Markowitz je prepoznao korist diversifikacije u formiranju optimalnog portfelja. Optimalni portfelji se nalaze na efikasnoj granici te najčešće imaju veći stupanj diversifikacije od portfelja koji se ne nalaze na efikasnoj granici, odnosno nisu optimalni.

Dio skupa minimalne varijance koji prikazuje portfelje koji za zadanu standardnu devijaciju imaju maksimalan prinos naziva se efikasnom granicom (efficient frontier). Navedeno je prikazano na slici 4.



Slika 4. (a) skup minimalne varijance (b) efikasna granica

Izvor: Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 139.

Za portfelj se može reći da je efikasan samo ako ne postoji drugi portfelj koji ima (Žiković, 2005., str. 19):

- ☐ veću očekivanu stopu prinosa i manju standardnu devijaciju
- ☐ veću očekivanu stopu prinosa i istu standardnu devijaciju ili
- ☐ istu očekivanu stopu prinosa i manju standardnu devijaciju

Matematički, efikasni portfelj možemo definirati kao (Aljinović, Marasović, Šego, 2011., str.141.):

$$\max E(R_\pi) = \pi' E(R) = \sum_{i=1}^n \pi_i E(R_i) \quad (19).$$

Uz ograničenja:


$$\pi' S \pi = c \quad (20)$$

$$\sum_{i=1}^n \pi_i = 1 \quad (21)$$

gdje je c konstanta koja prikazuje rizik mjeren varijancom koji je investitor spreman prihvatiti.

U ovom modelu udjeli pojedinih dionica u portfelju π_i su nepoznate varijable $i \in \{1, 2, \dots, N\}$. Navedeno dovodi do pitanja: koliki udio pojedine dionice u portfelju mora biti da bi prinos portfelja bio maksimalan, uz zadani rizik (konstanta c). Također je važno napomenuti da udjeli π_i , $i \in \{1, 2, \dots, N\}$ ponekad mogu poprimiti i negativne vrijednosti, što je poznato pod pojmom kratke prodaje.

U sljedećem primjeru prikazana je neefikasnost portfelja C u odnosu na portfelj A koji ima veći očekivani prinos i manji rizik. Uspoređujući ga s portfeljem B također zaključujemo da je portfelj C neefikasan jer za jednaku stopu rizika portfelj B ima maksimalni prinos te se nalazi na efikasnoj granici, jednako kao i portfelj A. U tom slučaju može se reći da portfelji A i B dominiraju nad portfeljem C.



Slika 5. Primjer efikasnog i neefikasnog portfelja

Izvor: Aljinović Z., Marasović B., Šego B. (2011): „Financijsko modeliranje“, Split: Sveučilište u Splitu, Ekonomski fakultet Split, str. 141.

Investitor formira portfelj te se, ovisno o osobnoj averziji prema riziku, pozicionira duž efikasne granice. U situaciji kada investitor ne želi preuzeti značajan rizik, njegov portfelj bit će smješten na efikasnoj granici u blizini točke minimalne varijance. Ukoliko preferira veći prinos bez obzira na rizik, njegov će optimalni portfelj biti udaljeniji od točke minimalne varijance na efikasnoj granici.

2.3. Doprinosi i kritike moderne teorije portfelja

Markowitzeva moderna teorija portfelja predstavlja najznačajniju inovaciju 20. stoljeća na području investiranja i upravljanja portfeljem vrijednosnih papira (Žiković, 2005., str. 21.). Koncept moderne teorije portfelja teorijski je jednostavan i empirijski dokazan kao pouzdan u normalnim tržišnim uvjetima. Markowitzev model prvi je model koji je uspio kvantitativno opisati rizik. Također je prvi model koji ukazuje na važnost diversifikacije te značaj korelacije vrijednosnica koje formiraju portfelj.

Dakle, tri su važna doprinosa moderne teorije portfelja:


- Kvantificiranje i optimizacija rizika
- Korelacija vrijednosnica koje sačinjavaju portfelj
- Diversifikacija

Do 1952. godine nije postojao odgovor na pitanje: kako izabrati dionice koje će sačinjavati portfelj? Markowitz je razvojem modela dokazao nužnost diversifikacije kako bi se formirao efikasan portfelj i reducirao rizik te postavio osnovu za razvoj svih drugih poboljšanih modela optimizacije portfelja (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 27). Korištenjem učinka diversifikacije i moderne teorije portfelja investitori mogu kreirati portfelje koji su istovremeno i profitabilniji i nose manji rizik (Cohen, Pogue, 1967., str. 185).

Diversifikacijom portfelja ne može se postići potpuna eliminacija rizika jer se ukupni rizik sastoji od dvije osnovne komponente, a to su: sustavni i nesustavni rizik. Sustavni rizik naziva se još i tržišni rizik odnosno rizik kojeg nije moguće izbjeći u potpunosti. Pokazuje stupanj sustavnog kretanja prinosa dionice povezanog s kretanjem prinosa ukupnog tržišta vrijednosnica (Morić-Milovanović, Ćurković, 2014., str. 392).

Nesustavni rizik za razliku od sustavnog rizika je onaj na kojeg je moguće utjecati. Veći broj vrijednosnica umanjuje rizik kojem se izlaže investitor, budući da se ne fokusira na rizik i prinos koji nosi pojedina vrijednosnica već cijeli portfelj. Prema Markowitzevom modelu diversifikacija portfelja odnosno formiranje portfelja kombinirajući vrijednosnice iz različitih sektora umanjiti će nesustavni rizik kojem je izložen investitor (Kunovac, 2010., str. 2).

Slika 6 prikazuje pozitivan učinak diversifikacije na smanjenje rizika ulaganja. Povećanjem broja vrijednosnica u portfelju ukupni rizik se smanjuje te približava razini sustavnog rizika.



Slika 6. Sustavni i nesustavni rizik

Izvor: Tomić-Plazibat N., Aljinović Z., Marasović B. (2006): „Matematički modeli u financijskom upravljanju“, Sveučilište u Splitu, Ekonomski fakultet Split, str. 29.

Koncept diversifikacije pridonio je povećanju ulaganja u inozemstvo, budući da su investitori počeli međunarodno diversificirati svoje portfelje. Investiranjem na različita svjetska tržišta moguće je postići veću diversifikaciju nego što je to moguće investiranjem u jednoj zemlji (Van Horne, 1993., str. 64).

Na mogućnost diversifikacije portfelja utječu različite turbulencije na tržištu. Za vrijeme mirnih perioda na tržištu kapitala korelacija koja se javlja između vrijednosnica je mala što omogućava uspješnu diversifikaciju portfelja. S druge strane turbulentnost tržišta rezultirat će porastom korelacije između vrijednosnica te otežati diversifikaciju portfelja (Kunovac, 2010., str. 2).

Iako je Markowitzev model predstavljao značajan napredak u području investiranja, model nije savršen te sukladno tome nije prošao bez primjedbi i kritika.

Jedna od najvećih kritika je temeljna pretpostavka Markowitzeva modela da su prinosi normalno distribuirani. U praksi to nije čest slučaj s obzirom da većina rezultata istraživanja na tržištima kapitala pokazuje asimetričnu ili šiljastu distribuciju. Distribucije prinosa najviše se razlikuju od normalne distribucije za vrijeme izrazitog gospodarskog uzleta ili gospodarske krize.

Sljedeća kritika Markowitzevog modela odnosi se na potrebu za izračunavanjem velikog broja standardnih devijacija i korelacija prinosa koji su uzeti u analizu stoga je rijetko bio korišten u praksi. Spomenuta kritika bila je više kritizirana u vrijeme nastanka ovog modela zbog obujma i složenosti izračuna velikog broja parametara. No, zahvaljujući razvoju računala i softvera problem optimizacije portfelja može se riješiti brzo i efikasno primjenom Markowitzevog modela (Tomić-Plazibat, Aljinović, Marasović, 2006., str. 26).

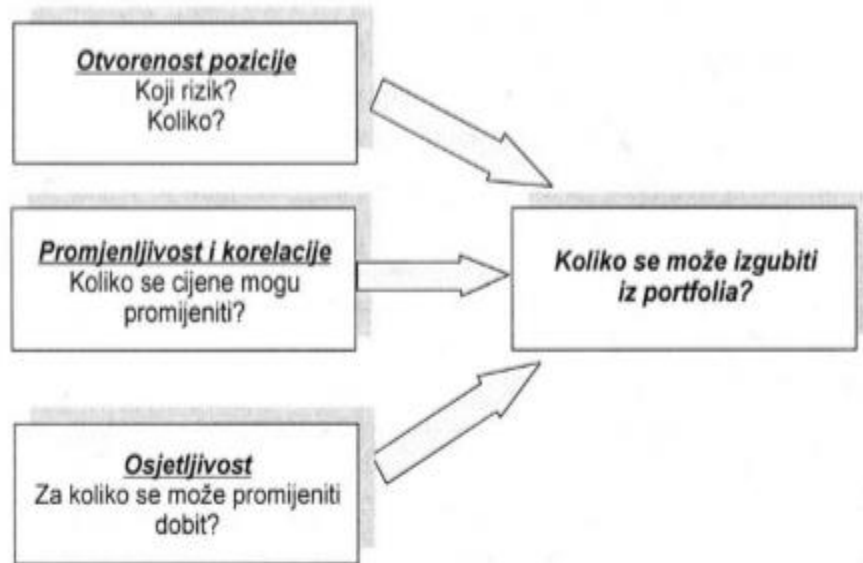
Ostale kritike uključuju pretpostavke racionalnosti investitora i njihove nesklonosti riziku, koje u nekim slučajevima nisu točne, te pretpostavku dobre informiranosti svih investitora za koju je poznato da zbog asimetrije informacija i agencijskog problema nije u potpunosti točna. Transakcijski troškovi i utjecaj poreza, kao i nemogućnost savršenog usitnjavanja vrijednosnica, također predstavljaju prepreke ovom modelu (Aljinović, Jerončić, 2011., str. 587).

Unatoč nesavršenosti, Markowitzev model predstavlja najveći i najznačajniji iskorak u području investiranja. Činjenica da se proučava i koristi 60 godina nakon nastanka dovoljno govori o važnosti Markowitzeve inovacije. Investitori koji su primijenjivali njegov model u 20. Stoljeću imali su značajnu prednost u odnosu na konkurenciju. MV modelom postavljeni su temelji za razvoj novih unaprijeđenih modela koji napreduju sukladno razvoju tehnologije.

2.4. Rizičnost vrijednosti

Rizičnost vrijednosti (Value at Risk ili VaR) je aproksimacija budućeg maksimalnog gubitka portfelja s određenom vjerojatnošću. Svrha je taj maksimalni gubitak iskazati u jednoj brojci. U toj se metodi koriste povijesni podaci za određivanje potencijalnog gubitka (Koch, MacDonald, 2000., str. 183).

Metoda rizične vrijednosti može se prikazati kao na slici 7.



Slika 7. Metoda rizične vrijednosti

Izvor: Šverko I. (2002): „Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima u financijskim institucijama“, Ekonomski pregled, Vol. 53 No.7-8, str. 644.

Rizična vrijednost, dakle, uzima u obzir otvorenost pozicije, promjenljivost, koeficijente korelacije i osjetljivosti svake pojedine stavke portfelja. Ta se metoda može primijeniti na mnoge aktivne instrumente, kao što su vlasničke i dužničke vrijednosnice, devize, derivati i slično (Šverko, 2002., str. 644).

Potreba za učestalijim kontroliranjem i mjerenjem rizika javila se početkom osamdesetih godina prošlog stoljeća kada su vodeće financijske institucije, zbog čestih nenagoviještenih kriza na tržištima, započele razvoj internih modela za mjerenje tržišnih rizika. Najznačajniji od svih modela je RiskMetrics od investicijske banke J.P. Morgan koji je u potpunosti otkriven javnosti 1994. godine. Osnovna ideja koja je potakla razvoj ovog modela nastala je kada je tadašnji direktor Danny Weatherstone naredio svojim zaposlenicima da mu na kraju svakog radnog dana dostave procjenu potencijalnih gubitaka u idućem danu te da im izvještaj sadrži samo jedan broj. RiskMetrics model temelji se na modernoj teoriji portfelja. Dakle, model procjenjuje rizik pomoću iznosa standardnih devijacija i koeficijenata korelacija vrijednosnica u portfelju. Od tada, J.P. Morgan svakodnevno objavljuje podatke o cjenovnim kretanjima i koeficijentima korelacije instrumenata za četiri tržišta u trideset zemalja svijeta.

Dva osnovna parametra koja definiraju VaR i koja su nužna za njegov izračun su:

- Razina pouzdanosti α
- Vremensko razdoblje t

Razina pouzdanosti se uglavnom kreće između 90% i 99%. Pojedina poduzeća koriste i po nekoliko različitih razina pouzdanosti (npr. 95% i 99%). Činjenica da VaR model pokazuje najveći mogući gubitak za određenu razinu vjerojatnosti razlikuje ga od ostalih modela za mjerenje rizika koji pokazuju samo iznos mogućeg gubitka. Također, iznos VaR-a ovisi o međusobnoj korelaciji između vrijednosnica koje se nalaze u portfelju što predstavlja veliku prednost ovog modela u odnosu na ostale.

Vremensko razdoblje koje se koristi u VaR analizi aktivnih financijskih institucija (banaka i raznih fondova) je jedan dan. Za banke i nema smisla uzimati u obzir neko dulje razdoblje jer se tržište pozicije i odnosi mijenjaju dinamički iz dana u dan. S druge strane, investicijski menadžeri koriste razdoblje od jednog mjeseca, dok korporacije mogu koristiti kvartalne ili čak godišnje projekcije rizika (Aljinović, Marasović, Šego, 2011., str. 160).

Postoje četiri osnovne metode za izračun rizične vrijednosti. One su prikazane na slici 8.



Slika 8. Modeli izračuna rizične vrijednosti

Izvor: Šverko I. (2002): „Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Republici Hrvatskoj“, Financijska teorija i praksa, Vol. 25 No. 4, str. 646.

- ❖ RiskMetrics model - poznat je u praksi pod drugim nazivima kao: parametarski model, delta normalan model, model varijance i kovarijance i linearni model. Izračun VaR-a parametarskom metodom vrši se na način da se pretpostavi da distribucija prinosa odgovara nekoj od teorijskih distribucija, kao što je normalna distribucija. Primjenom ove pretpostavke, VaR za tržišni rizik izračunava se na temelju dva osnovna parametra: srednje vrijednosti dobitaka/gubitaka (ili stope prinosa) promatranog portfelja, te standardne devijacije promatranih podataka. Iako za parametrijski pristup određivanja VaR-a nije potrebna pretpostavka da su dobitci/gubici portfelja normalno raspoređeni najčešće se pri ovom načinu koristi upravo normalna distribucija ili približna alternativa, odnosno eliptična distribucija (Žiković, 2005., str. 64).
- ❖ Povijesni model - je najjednostavniji i najrasprostranjeniji model za izračun rizične vrijednosti. Povijesna simulacija spada u skupinu neparametrijskih metoda procjena VaR-a bez postavljanja pretpostavki o distribuciji prinosa. Temelji se na pretpostavci da će kretanje prinosa u budućnosti biti slično kretanjima prinosa u prošlosti te se na osnovu toga može prognozirati rizik u bliskoj budućnosti (Žiković, 2005., str. 74). Ne zasniva se na koeficijentima korelacije među dijelovima portfelja. Tom se metodom ocjenjuju tržišna

vrijednost portfelja s obzirom na tržišne cijene dijelova portfelja n posljednjih dana. Osnovna ideja tog koncepta je uzimanje u obzir trenutnog portfelja te ponovna ocjena njegove tržišne vrijednosti na osnovi tržišnih cijena iz prethodnih dana. Na osnovi cijena iz prošlosti određuje se „pretpostavljena“ tržišna vrijednost trenutnog portfelja u n posljednjih dana. Nakon toga se tako dobivene tržišne vrijednosti poredaju od onih koje daju najveće gubitke do onih koji donose najveće dobitke, te se tako dolazi do rizične vrijednosti ili najvećeg očekivanog gubitka promatranog portfelja (Šverko, 2001., str. 608).

- ❖ Monte Carlo simulacija - je najkompleksniji, ali i najtočniji model izračuna rizične vrijednosti. Osnovna pretpostavka RiskMetrics modela jest da se dobiti ili gubici iz portfelja distribuiraju normalnom krivuljom. Pretpostavi li se da takva postavka nije realna, može se razviti povijesni model koji se zasniva na povijesnim podacima, to jest na pretpostavci da će se buduće promjene kretati baš kao i u prošlosti. Međutim, ako se pretpostavi da ni to predviđanje nije dovoljno realno, uvodi se Monte Carlo simulacija, sa zadatkom statičkog generiranja slučajnih scenarija na osnovi kojih će se odrediti rizična vrijednost (Šverko, 2001., str. 610). Ova vrsta simulacije pokriva širok spektar matematičkih modela i algoritama i u potpunosti uzima u obzir njihove međusobne korelacije. Korištenjem Monte Carlo simulacije pri izračunu VaR-a nasumično se stvaraju mnogobrojni scenariji za buduća kretanja tržišnih varijabli, a nelinearnim vrednovanjem se za svaki scenarij izračunavaju vrijednosti promjena. Vrijednost VaR-a izračunava se uzimanjem najvećeg gubitka uz određenu razinu vjerojatnosti (Žiković, 2005., str. 69).
- ❖ Testiranje stresnih situacija – je zapravo dopuna svih klasičnih VaR modela. To je analiza scenarija koja procjenjuje kolika bi bila vrijednost nekog portfelja ako bi se dogodio neki stresni scenarij (rast ili pad kamatnih stopa za 200 baznih poena ili slično). Potrebno je naglasiti da se vrlo često u financijskim izvještajima poduzeća, osim izvještaja maksimalnog očekivanog gubitka portfelja (nekim od klasičnih VaR modela), navodi i određena vrijednost tih portfelja izračunata testiranjem stresnih situacija (Šverko, 2001., str. 610).

Spomenuta četiri modela rizičnosti vrijednosti imaju mnogobrojne sličnosti, iako im se rezultati često razlikuju. Svaki pristup koristi faktore rizika kao što su kamatna stopa, intervalutni tečajevi i volatilnost. Također, svim modelima cilj je određivanje odgovarajuće distribucije koju izračunaju na temelju povijesne distribucije promjene cijena na tržištu. S promatranjem povijesne distribucije modeli se suočavaju s problemom odabira vremenskog horizonta jer je nemoguće istovremeno zadovoljiti dva ekstrema kojima se teži. S obzirom da se izračunom rizičnosti vrijednosti želi predvidjeti buduća kretanja potrebno je koristiti najnovije tržišne podatke, ali također je bitno obuhvatiti dovoljno dugo povijesno razdoblje kako bi analiza sadržavala gubitke u ekstremnim situacijama. Nemoguće je zadovoljiti oba ekstrema stoga je potrebno pronaći kompromis.

Najveće prednosti VaR modela je što na jednostavan način prikazuje mjeru rizika za različite pozicije i faktore rizika te što uzima u obzir međusobnu korelaciju vrijednosnica. Iako ima nedostatke, značajno je pridonio napretku u sigurnosti poslovanja.

2.5. Beta – mjera sustavnog rizika

Ključni problem svakog izračuna očekivane stope prinosa određene investicije predstavlja procjena beta koeficijenta. Beta je relativna mjera rizika koja pokazuje osjetljivost promjene prinosa vrijednosnice na promjene prinosa tržišnog portfelja. Matematički, beta koeficijent financijskog instrumenta je njegova kovarijanca u odnosu na tržišni portfelj, podijeljena sa varijancom tržišnog portfelja. Navedena definicija prikazana je izrazom:

$$\beta_n = \frac{COV_{nm}}{\sigma_m^2} \quad (22)$$

gdje su:

β_n – beta koeficijent dionice n

COV_{nm} – kovarijanca prinosa dionice n i tržišta m

σ_m^2 – varijanca tržišnog portfelja m

S obzirom da beta pokazuje koliko je sustavnog rizika u pojedinoj aktivi u odnosu na prosječnu aktivu u kojoj rizik iznosi 1, vrijednost beta koeficijenta može biti manja, jednaka ili veća od 1.

Ukoliko je $\beta=1$, kretanja prinosa vrijednosnice pojedinog poduzeća proporcionalna su kretanjima prinosa tržišnog portfelja, odnosno vrijednosnica ima istu razinu sustavnog rizika kao i tržište u cjelini.

U slučaju da je $\beta>1$, prinos vrijednosnice varira više od prinosa tržišnog portfelja, odnosno sustavni rizik vrijednosnice pojedinog poduzeća veći je od rizika tržišta u cjelini. Takva vrsta dionica često se naziva agresivna investicija.

Ukoliko je $\beta<1$, sustavni rizik pojedine vrijednosnice manji je od sustavnog rizika tržišnog portfelja. Vrijednosnice ovakvih karakteristika nazivaju se obrambene te su im premije na rizik manje od tržišnih.

Navedene vrijednosti bete, prikazuju situaciju kada očekivani prinos vrijednosnice ima pozitivnu korelaciju sa visinom β koeficijenta (Radović, Vasiljević, 2012., str. 426).

Beta također može imati i negativnu vrijednost ($\beta<0$) što pokazuje da se prinos vrijednosnice kreće u obrnutom smjeru od kretanje tržišnog portfelja kreću u suprotnim smjerovima. U slučaju kada je $\beta=0$, ulaganje ne sadrži rizik.

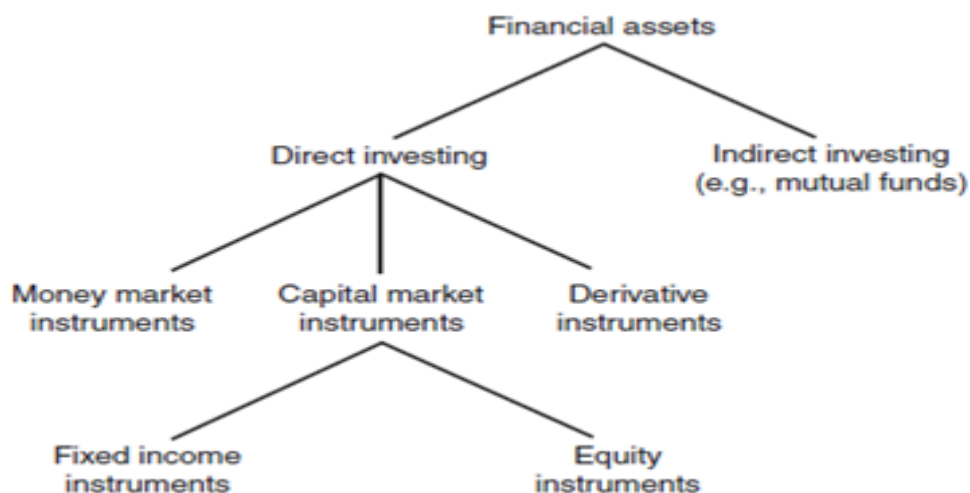
Najčešće se u analizama koriste mjesečni prinosi, ali zbog dinamičnosti promjena i kratkog vremenskog intervala u trgovanju na pojedinim tržištima kapitala, nije zanemareno ni korištenje tjednih i dnevnih prinosa. Smatra se da je korištenje mjesečnih prinosa uglavnom pogodno za pasivne strategije investiranja, dok je kod aktivnih strategija potrebno imati beta koeficijente iz kraćih razdoblja.

Kod standardne VaR metode, beta se koristi za izračun rizika pojedine dionice, na način da se pomnoži beta koeficijent i volatilnost indeksa tržišta, čime se izbjegava izračun velikog broja kovarijanci (Latković, 2001., str. 6).

3. WALL STREET I PREDSEDNIČKI IZBORI U SAD-U

3.1. Američko tržište kapitala

Financijsko tržište je, najjednostavnije objašnjeno, prostor na kojem se susreću ponuda i potražnja financijskih sredstava (Orsag, Dedi, 2014., str. 10). Odnos koji se stvara između ponude i potražnje oblikuje njihovu cijenu. Financijska tržišta, ovisno o stupnju likvidnosti i broju sudionika, mogu biti razvijena i nerazvijena. Nerazvijena financijska tržišta svedena su na depozit, kredit i banke. Razvijena tržišta obiluju financijskim instrumentima, raznovrsnim financijskim institucijama, složenim financijskim tehnikama i brojnim financijskim tokovima. Financijsko tržište najbitniji je element financijskog sustava. Također se može definirati kao mjesto odvijanja procesa financiranja i razvoja poduzeća što je njegova primarna uloga. Dakle, na financijskom tržištu se odvija mobilizacija slobodnih novčanih sredstava i njihovo alociranje u potencijalno profitabilne projekte. Spomenuto alociranje sredstava odvija se putem financijskih instrumenata. Financijski instrumenti su, u najširem smislu riječi, ugovori u kojima su sadržana prava i obveze iz nekog financijskog odnosa (Orsag, Dedi, 2014., str.10). Ulaganje u njih može biti direktno (aktivno ulaganje) i indirektno (pasivno ulaganje).



Slika 9. Vrste financijskih instrumenata

Izvor: Elton E.J. et al. (2007): „Modern portfolio theory and investment analysis“, New Jersey: John Wiley and Sons, Inc., Vol. 7, str.12.

Pasivno ulaganje podrazumijeva ulaganje u dionice fondova čijom kupnjom zapravo posjedujemo udio u diversificiranom portfelju tih fondova, dok aktivno moguće ulagati u instrumente tržišta novca, kapitala i izvedenica. Najpoznatiji instrumenti tržišta novca su trezorski zapisi (T-Bills), certifikati o depozitu banaka (CDs) i repo ugovori. Instrumente tržišta kapitala dijelimo na instrumente fiksnih prinosa (obveznice) i dionice, dok izvedenice mogu biti opcije, forward ugovori, futures ugovori i swap ugovori te njihova profitabilnost ovisi o učinku osnovnog instrumenta iz kojeg su izvedeni.

Postoje različiti kriteriji prema kojima se financijska tržišta mogu podijeliti. Najstandardniji kriteriji su prema prirodi trgovanja (primarno i sekundarno tržište) i prema vremenu raspolaganja financijskim sredstvima (tržište novca i tržište kapitala). Na primarnom tržištu poduzeća pribavljaju novčana sredstva izdavanjem novih vrijednosnih papira, dok se na sekundarnom tržištu trguje postojećim vrijednosnicama. Tržište novca predstavlja tržište kratkoročnih vrijednosnica, dok tržište kapitala predstavlja tržište vrijednosnih papira s dugim rokom raspolaganja.

Tržište kapitala najznačajnije je sa stajališta pribavljanja novčanih sredstava potrebnih za poslovanje i ekspanziju dioničkih društava i drugih organizacijskih oblika poduzeća jer predstavljaju tržište za najveći dio dugoročnih potreba poduzeća. Tržište kapitala određeno je kao tržište dugoročnih vrijednosnih papira. U širem smislu tržište kapitala obuhvaća i dogovorno tržište dugoročnih kredita, kao i tržište financiranja rizičnih poslova, odnosno dogovorno tržište glavnica (Orsag, Dedi, 2014., str. 19). Tržište kapitala u užem smislu može biti primarno (emisijsko) i sekundarno. Sekundarna tržišta, odnosno tržišta na kojima se trguje postojećim vrijednosnim papirima, dijele se na organizirana i spontana tržišta. Tercijarno tržište odnosi se na organizirano trgovanje vrijednosnim papirima na burzi te trgovanje preko dilera, odnosno njihovih šaltera (eng. OTC – Over the counter). OTC tržište je dogovorni oblik tržišta na kojima se trguje posredstvom dilera koji nemaju fiksno mjesto trgovanja (mreža dilerskih šaltera) i koje nije strogo formalizirano. Posebno je razvijeno u Sjedinjenim Američkim Državama gdje omogućuju manjim poduzećima, čije vrijednosnice nisu uvrštene na burzu, da formiraju cijenu svojih dionica na slobodnom tržištu.

Na burzi trguju samo ovlaštteni trgovci, strogo je formalizirana te poduzeća koja žele kotirati svoje vrijednosne papire moraju udovoljiti strogim zahtjevima burze. Glavna razlika između burze i OTC tržišta je u transparentnosti, odnosno podaci potrebni za donošenje odluka o investiranju na burzama su omogućeni i dostupni svima, dok na OTC tržištima nisu.

Kvartalno tržište kapitala čini trgovinsku mrežu između velikih institucionalnih investitora koji trguju velikim blokovima vrijednosnih papira. Razlog postojanja ovog tržišta leži u smanjivanju transakcijskih troškova za velike blokove vrijednosnih papira kao i u nastojanju da se takvim velikim transakcijama ne utječe na njihove cijene na burzi (Orsag, Dedi, 2014., str. 23).

Opisana struktura tržišta kapitala prikazana je na slici 10.



Slika 10. Struktura tržišta kapitala

Izvor: Orsag S., Dedi L. (2014): „Tržište kapitala“, Zagreb: Alka script, str. 19.

Američko tržište kapitala u najvećem omjeru ovisi o dvije najveće svjetske burze, New York Stock Exchange (NYSE) i NASDAQ Stock Market, te se često poistovjećuje s nazivom Wall Street. Wall Street je ulica na Manhattan-u u New Yorku, a često se koristi kao naziv za cjelokupnu financijsku i investicijsku zajednicu u Sjedinjenim Američkim Državama.

Područje Wall Street-a postalo je središte trgovinske razmjene početkom 18. stoljeća, a 17. svibnja 1792. godine 24 brokera potpisuju Buttonwoodski sporazum kojim službeno započinje trgovanje vrijednosnicama u New York-u. Prvi vrijednosni papiri koji su bili predmet trgovine bile su ratne obveznice iz Revolucijskog rata i dionice prve banke u Sjedinjenim Američkim Državama. Obujam dionica kojima se trgovalo značajnije počinje rasti krajem 19. i početkom 20. stoljeća. Nakon Prvog svjetskog rata, New York, ponajprije zahvaljujući Wall Street-u, prestiže London te postaje najznačajnije svjetsko financijsko središte. Wall Street je dom dvije najveće svjetske burze, New York Stock Exchange (NYSE) i NASDAQ (National Association of Securities Dealers Automated Quotations) Stock Market.

NYSE je najpoznatija, a ujedno i najznačajnija svjetska burza na kojoj kotiraju vrijednosni papiri više od 2300 dioničkih društava. Osnovana je 17. svibnja 1792. godine Buttonwoodskim sporazumom, a formalno je organizirana 8. ožujka 1817. godine kada je usvojen Ustav te je naziv burze proširen u „New York Stock & Exchange Board“. Za prvog predsjednika burze izabran je Anthony Stockholm. Prva od velikih katastrofa koje su potresli NYSE dogodila se u prosincu 1835. godine kada je izbio veliki požar u kojemu je izgorjela i zgrada burze gdje su se održavale sjednice odbora. 1863. godine burza mijenja naziv u „New York Stock Exchange“ koji se i danas službeno koristi. U 20. stoljeću, paralelno s industrijskom revolucijom, rastao je i obujam dionica kojim se trgovalo. Upravo zbog povećanja opsega trgovanja, 1903. godine otvorena je nova zgrada burze, a 6 godina kasnije ponuda je proširena omogućavanjem trgovanja obveznicama. Jedan od značajnijih događaja koji su potresli NYSE, ali i ostale svjetske burze, je „Velika gospodarska kriza“ kojoj je prethodio „crni četvrtak“ kada je zavládala panika na burzi zbog precijenjenih cijena dionica američkih poduzeća. Sljedećeg tjedna 24. listopada 1929. godine dolazi do definitivnog kraha američkih dionica koji je poznat kao i „crni utorak“ kojim je započela kriza koja je trajala do 1933. godine te koja je uzrokovala slom najvažnijih nacionalnih gospodarstava. Na novi potres čekalo se sve do listopada 1987. godine kada je indeks Dow Jones (DJIA) u jednom danu pao za čak 22,6% (508 bodova). Godinu dana kasnije otvoren je ured u

Londonu koji je omogućio europskim poduzećima lakši pristup američkim vrijednosnicama. Najnoviji potres na burzi u New Yorku dogodio se 2007. godine nastupanjem financijske krize koju su velikim dijelom uzrokovale globalne investicijske banke koje kotiraju upravo na NYSE-u. Godine 2007. New York Stock Exchange je nadmašila konkurenciju spajanjem s amsterdamskom elektroničkom burzom Euronext, čime je nastala prva globalna svjetska burza.

Na Wall Street-u se nalazi i NASDAQ Stock Market, druga najveća svjetska burza prema tržišnoj kapitaliziranosti. Kad je počela s radom 8. veljače 1971. godine bila je prva svjetska elektronička burza dionica te je uspjela značajno smanjiti razliku između kupovne i prodajne cijene (spread). Upravo je zbog toga u svojim počecima bila neprivlačna brokerima koji su zarađivali velik novac zahvaljujući toj razlici. NASDAQ Stock Market je pionir OTC (over-the-counter) tržišta koje nema fiksno mjesto trgovanja već se trguje preko mreže dilerskih šaltera. Također je odigrala značajnu ulogu u moderniziranju inicijalne javne ponude (IPO) te je privukla nove brzorastuća poduzeća od kojih su najznačajniji Microsoft, Apple, Amazon, Oracle i Dell. U 2006. godini NASDAQ Stock Market proširuje svoje ponudu, dakle, prestaje biti tržište dionica, a postaje licencirano tržište vrijednosnica. Da bi bilo kvalificirano za kotiranje na burzi, poduzeće mora biti registrirano u SEC-u (Securities and Exchange Commission), mora imati najmanje tri financijska poduzeća koja će biti brokeri i dileri za odgovarajuće dionice (money makers) te mora posjedovati odgovarajuće minimalne kriterije za imovinu, kapital, javne dionice i dioničare. Sljedeće godine proširuje se globalno spajajući se s OMX grupom, vodećim tržišnim operatorom u nordijskim zemljama, te mijenja ime u NASDAQ OMX Group. U studenom 2016. godine Adena Friedman unaprijeđena je u ulogu CEO (Chief Executive Officer) burze te postaje prva žena koja je upravlja burzom u Sjedinjenim Američkim Državama. S otprilike 3 300 kompanija, NASDAQ ima više prijavljenih poduzeća i u prosjeku se trguje s više dionica po danu nego na drugim američkim burzama.

3.1.1. Temeljne odrednice Wall Street-a

S obzirom da se dvije najveće svjetske burze prema tržišnoj kapitaliziranosti nalaze se na Wall Street-u u New York-u, svjetska ekonomija značajno ovisi o poduzećima koje kotiraju na dotičnim burzama. NYSE je najveća svjetska burza prema tržišnoj kapitaliziranosti te predstavlja oko 27% svjetske tržišne kapitalizacije. Ukoliko tome pridodamo 13% svjetske tržišne kapitalizacije koje se odnosi na NASDAQ, dolazimo do zaključka da američko tržište kapitala sadrži oko 40% tržišne kapitalizacije svih svjetskih burzi.

Značaj spomenutih burzi u svjetskom financijskom sustavu je očigledan s obzirom da većina najvećih i najznačajnijih svjetskih korporacija kotira upravo na Wall Street-u. Na kraju 2015. godine na New York Stock Exchange-u kotirale su dionice od 2424 poduzeća, dok se taj broj na kraju 2016. godine smanjio za 117 te je iznosio 2307 dionica različitih poduzeća. U odnosu na 2015. godinu smanjio se broj domaćih (s 1910 na 1822), ali i stranih poduzeća (s 514 na 485) koje kotiraju na burzi. Smanjenje broja poduzeća koje kotiraju na burzi nije se odrazilo na smanjenje tržišne kapitalizacije te je ona narasla sa 18,4 trilijuna američkih dolara na kraju 2015. godine na 20,2 trilijuna američkih dolara na kraju 2016. godine.

Iako je NASDAQ Stock Market manja od NYSE prema tržišnoj kapitaliziranosti, broj poduzeća koje kotiraju na NASDAQ burzi veći je nego broj poduzeća koje kotiraju na NYSE-u. Također, za razliku od NYSE, NASDAQ nije zabilježio pad broja listanih poduzeća u 2016. godini. Naprotiv, broj poduzeća koje kotiraju na burzi na kraju 2016. godine iznosio je 2897 što je povećanje od 38 poduzeća u odnosu na isto razdoblje u 2015. godini kada je taj broj iznosio 2859 poduzeća. Broj domaćih kompanija na kraju 2015. godine iznosio je 2471 te se do kraja 2016. godine povećao na 2509, dok je broj stranih poduzeća koje kotiraju na burzi ostao nepromijenjen (388).

Usporedba tržišne kapitalizacije i prosječne cijene dionica prema mjesecima u 2015. i 2016. godini na New York Stock Exchange-u prikazana je u sljedećoj tablici.

Tablica 1. Tržišna kapitalizacija NYSE u 2015. i 2016. godini

	2015. godina		2016. godina	
Mjesec	Tržišna kapitalizacija (u \$)	Prosječna cijena dionica (u \$)	Tržišna kapitalizacija (u \$)	Prosječna cijena dionica (u \$)
Siječanj	20.078.246.960.244	42,63	17.375.532.205.280	37,56
Veljača	20.385.204.634.064	44,70	18.186.399.324.941	39,60
Ožujak	20.175.359.864.188	44,03	18.745.416.638.497	40,89
Travanj	20.342.308.665.814	44,74	19.104.399.823.371	41,74
Svibanj	20.373.343.575.589	44,40	19.132.641.933.379	41,88
Lipanj	19.904.589.003.166	43,33	19.294.672.427.663	42,53
Srpanj	19.990.232.862.991	43,47	19.452.478.336.397	43,60
Kolovoz	18.548.987.707.312	39,95	19.601.807.866.050	43,65
Rujan	18.932.580.463.615	40,87	19.519.255.818.488	43,21
Listopad	19.283.462.647.244	41,74	18.768.718.607.540	41,96
Studeni	19.105.747.688.853	41,25	19.623.625.947.091	43,78
Prosinac	18.375.751.363.903	39,86	20.215.457.437.540	45,21

Izvor: http://www.nyxddata.com/nysedata/asp/factbook/viewer_edition.asp?mode=table&key=3337&category=5

Tablica 1 prikazuje kretanje tržišne kapitalizacije i prosječne cijene dionica u razdoblju od dvije godine. U 2015. i 2016. godini tržišna kapitalizacija se uglavnom kretala između 18 i 20 trilijuna dolara s najnižim iznosom od 17,4 trilijuna u siječnju 2016. godine te najvišim iznosom od 20,4 trilijuna dolara u veljači 2015. godine. Tržišna kapitalizacija nakon početka 2015. godine počinje opadati. Trend je zaustavljen u veljači 2016. godine kada tržišna kapitalizacija ponovo raste te do kraja godine približava razini s početka 2015. godine. Također se uočava povezanost kretanja prosječne cijene dionica i tržišne kapitalizacije. Najmanja prosječna cijena dionica zabilježena je siječnju 2016. godine te je iznosila 37,56 dolara dok je najveća cijena zabilježena u prosincu iste godine kada je prosječna cijena iznosila 45,21 dolar po dionici. Gotovo identična kretanja prosječne cijene dionica u odnosu na tržišnu kapitalizaciju insinuiraju zaključak da rast (pad) tržišne kapitalizacije utječe na porast (pad) prosječne cijene dionica, i obrnuto.

Pozitivan trend rasta tržišne kapitalizacije nastavio se i u 2017. godini kada je tržišna kapitalizacija New York Stock Exchange-a dosegla rekordnih 21,3 trilijuna američkih dolara u lipnju 2017. godine. Prosječna cijena dionica koje kotiraju na burzi u istom mjesecu u 2017. godini iznosila je 47,02 američka dolara. NYSE je otvorena za trgovanje od ponedjeljka do petka od 9:30 do 16:00 sati po lokalnom vremenu.

Rast tržišne kapitalizacije također je nastavljen i na NASDAQ Stock Market-u te je prešao granicu od 8 trilijuna američkih dolara što je najveći iznos tržišne kapitalizacije u povijesti burze. Radno vrijeme NASDAQ Stock Market-a je također od 9:30 do 16:00 sati po lokalnom vremenu.

3.1.2. Indeksi Wall Street-a

NYSE I NASDAQ sadrže mnogo različitih indeksa. Najvažniji indeksi na spomenutim burzama, ali i najznačajniji svjetski indeksi su Dow Jones indeks te S&P 500 indeks. Također vrijedi spomenuti indekse poput NYSE Composite indeks te NASDAQ Composite indeksa.

Dow Jones indeks najpoznatiji je burzovni indeks na svijetu. Kreirao ga urednik Wall Street Journal-a Charles Dow 1896. godine. Dow Jones industrijski indeks (DJIA) je glavni dio svakog burzovnog izvješća te je najpoznatija mjera izvedbe tržišta dionica (Bodie, Kane, Marcus, 2014., str. 44). Indeks pokazuje izvedbu 30 velikih javnih korporacija iz SAD-a (“blue chip“ poduzeća) na tržištu dionica. Izračunava se kao vagana aritmetička sredina prosječnih cijena dionica (price-weighted average) od 30 velikih američkih korporacija. Dakle, Dow Jones indeks je zbroj prosječnih cijena dionica prilagođenih za strukturne promjene unutar indeksa poput podjele dionica, zamjena poduzeća unutar grupe s poduzećem izvan grupe te isplata dividendi iznad 10% (Bodie, Kane, Marcus, 2014., str. 45):

$$DJIA = \frac{\sum p}{d} \quad (23)$$

gdje su:

p – prosječne cijene dionica poduzeća unutar Dow Jones indeksa

d – Dow djelitelj

Dow djelitelj dugo je bio jednak broju dionica (30) koje sačinjavaju indeks stoga je Dow Jones bio aritmetička sredina prosječnih cijena dionica od 30 američkih korporacija. Kako bi se sačuvao kontinuitet cijene indeksa, potrebno je prilagođavati Dow djelitelj u slučaju strukturnih promjena. Trenutno je Dow djelitelj manji od 1 te je 1. rujna 2017. godine iznosio 0.14523396877348 što znači da je cijena Dow Jones indeksa veća od prosječne cijene svih poduzeća koje sačinjavaju indeks. Dakle, svaka promjena cijene dionice određenog poduzeća od 1\$ pomiče indeks za 6.885 ($1 \div 0.14523396877348$) poena. Dow Jones indeks je trenutno sačinjen od 26 poduzeća koja kotiraju na New York Stock Exchange-u te samo 4 poduzeća koja kotiraju na NASDAQ Stock Market-u (Apple, Cisco Systems, Intel i Microsoft).

Standard & Poor's Composite 500 (S&P 500) indeks predstavlja poboljšanje Dow Jones indeksa na dva načina (Bodie, Kane, Marcus, 2014., str. 48). Prvo, predstavlja više američkih poduzeća (500) što bolje prezentira stvarno stanje ekonomije u SAD-u. Drugo, indeks je vagana aritmetička sredina tržišne kapitalizacije poduzeća (market-value-weighted indeks) što znači da utjecaj koji pojedino poduzeće ima na indeks ovisi o cijeni dionice i broju dionica u opticaju, a ne samo o cijeni kao što je u slučaju Dow Jones indeksa. S&P 500 prvi put je predstavljen javnosti 4. travnja 1957. godine i od tada je najznačajniji pokazatelj stanja ekonomije u Sjedinjenim Američkim Državama. Izračunava se zbroj svih tržišnih vrijednosti (prosječna cijena dionica pomnožena s brojem dionica u opticaju) poduzeća koja sačinjavaju S&P 500 korigiran za strukturne promjene unutar indeksa:

$$S\&P\ 500 = \frac{\sum(P_i \times Q_i)}{d} \quad (24)$$

gdje su:

P_i - prosječna cijena dionice pojedinog poduzeća unutar indeksa

Q_i - broj dionica u opticaju

d – djelitelj S&P 500 indeksa

S&P 500 indeks se kao i većina današnjih indeksa izračunava korištenjem modificirane verzije vagane tržišne kapitalizacije. Umjesto korištenja ukupne tržišne vrijednosti, za izračun indeksa

koristi se samo tržišna vrijednost dionica koje su dostupne za trgovanje (free float) što isključuje dionice koje posjeduju obitelji i države koje nisu aktivne na tržištu. Utjecaj pojedinog poduzeća na S&P 500 indeks ovisi o njegovoj tržišnoj kapitalizaciji u odnosu na ukupnu tržišnu kapitalizaciju svih 500 poduzeća. Najveći utjecaj ima Apple s približno 4% udjela u ukupnoj tržišnoj kapitalizaciji. S&P 500 djelatnik je u rujnu 2017. godine iznosio 8565,26 što predstavlja pad za 0,91% u odnosu na isto razdoblje u 2016. godini kada je djelatnik iznosio 8643,59. Identičan prinos kao portfelj dionica poduzeća koje sačinjavaju S&P 500 moguće je ostvariti ulaganjem u zajedničke indeksne fondove i ETF-ove koje sadrže iste dionice u jednakom omjeru kao i S&P 500 indeks.

Jedan od najvažnijih indeksa na američkom tržištu kapitala je NYSE Composite indeks. Sadrži dionice svih poduzeća koja kotiraju na New York Stock Exchange-u. Osim dionica obuhvaća i američke depozitarne račune te vrijednosnice koje izdaju fondovi nekretnina. U javnosti je prvi put predstavljen 31. prosinca 1965. godine. Indeks odražava kretanja preko 2000 dionica od čega je više od 1500 dionica američkih poduzeća. Iako je značajan postotak poduzeća unutar indeksa iz SAD-a, strana poduzeća imaju veliku tržišnu vrijednost stoga se od 100 najvrijednijih poduzeća čak 55 nalazi izvan granica SAD-a. Izračunava se kao vagana aritmetička sredina tržišne kapitalizacije dionica svih poduzeća koje su dostupne investitorima na NYSE-u (free float). Dvije najveće prednosti NYSE Composite indeksa su:

1. kvaliteta poduzeća – sva poduzeća koja kotiraju na burzi moraju ispunjavati stroge zahtjeve NYSE,
2. globalna diversifikacija – poduzeća sa sjedištem izvan granica SAD-a predstavljaju više od trećine ukupne tržišne kapitalizacije svih poduzeća unutar indeksa.

NASDAQ Composite indeks predstavlja kretanje dionica svih poduzeća koje kotiraju na NASDAQ Stock Market-u te slične vrijednosnice poput američkih depozitarnih računa, pratećih dionica (tracking stocks) te vrijednosnica fondova nekretnina (REITs). Nije ograničen na dionice poduzeća sa sjedištem u SAD-u te se također izračunava metodom vagane aritmetičke sredine tržišne kapitalizacije korigirane za strukturne promjene. Kreiran je 1971. godine te trenutno sadrži od više od 3000 različitih dionica. Poduzeća iz tehnološkog sektora imaju velik udio u ukupnoj tržišnoj kapitalizaciji svih poduzeća unutar indeksa te kretanje njihovih cijena na tržištu značajno utječe na kretanje NASDAQ Composite indeksa.

3.2. Predsjednički izbori u SAD-u u 2016. godini

Američki predsjednički izbori najbitniji su izbori na globalnoj razini te stoga imaju snažan utjecaj na svjetsku ekonomiju. Održavaju se svake četiri godine u utorak poslije prvog ponedjeljka u mjesecu studenom. Sjedinjene Američke Države imaju indirektni sustav izbora predsjednika što znači da svaki od 219 američkih državljana glasajući za predsjednika zapravo bira određeni broj elektora iz vlastite savezne države. Biraju se elektori iz 50 saveznih država i gradu Washingtonu (District of Columbia). Elektori u svim državama, osim Mainea i Nebraske, se biraju na način da kandidat za predsjednika koji dobije najviše glasova automatski dobiva sve elektorske glasove u toj saveznoj državi. Dakle, pobjeda u pojedinoj saveznoj državi odlučuje za koga će elektori iz te države glasati u izbornom kolegiju, tijelu koje službeno bira predsjednika SAD-a. Savezne države Maine i Nebraska dodjeljuju elektore proporcionalno broju glasova. Izborni kolegij ima 538 članova. Savezne države zastupljene su u izbornom kolegiju razmjerno broju stanovnika stoga Kalifornija ima najviše elektora (55), a slijede Teksas (38) te New York (29) i Florida (29). Slabo naseljene države poput Aljaske, Vermonta, Delawarea, Wyominga ili Montane imaju samo po tri elektora. Pobjednik izbora je kandidat koji skupi apsolutnu većinu elektorskih glasova (270).

Pri kraju drugog četvrtgodišnjeg mandata Baracka Obame, 8. studenog 2016. godine, održali su se 58. predsjednički izbori u Sjedinjenim Američkim Državama. Kandidati na spomenutim izborima bili su republikanac Donald Trump i demokratkinja Hillary Clinton.

3.2.1. Predizborne kampanje

Međunarodna enciklopedija političkih znanosti, kapitalno djelo nastalo kao plod suradnje stručnjaka s više vodećih svjetskih sveučilišta, kampanju definira kao „napor kandidata ili organizirane grupe da uvjeri određeni segment populacije u donošenje neke odluke” (Badie, Berg-Schlosser, Morlino, 2011., str. 181). Dakle, predizborna kampanja predstavlja proces oblikovanja imidža kandidata s ciljem pridobivanja većine glasačkog tijela. Stoga je predizborna kampanja ključna determinanta o kojoj ovisi uspjeh na predsjedničkim izborima.

Iako su Hillary Clinton i Donald Trump imali jednaki cilj, njihove predizborne kampanje su bile dijametralno suprotne. Dok je Hillary Clinton pokušavala formirati imidž snažne žene i staložene političarke s pregršt iskustva u političkom vrhu SAD-a, Donald Trump je nastojao kontroverzama dospjeti u centar medijske pažnje, a samim tim i javnosti. Kontroverznim nastupima koji su medijima bili iznimno interesantni, osigurao si je znatno jeftiniju promociju od protukandidatkinje. Vrijednost izvještavanja o republikanskom kandidatu bez narudžbe iznosila je 2 milijarde američkih dolara tijekom predizborne kampanje, dok je službeno ulaganje u medijski prostor iznosilo 10 milijuna američkih dolara (Confessore, Yourish, 2016.). Lukava strategija privlačenja medija okarakterizirana je kao jedan od najuspješnijih poteza u predizbornoj kampanji. Demokratska kandidatkinja je također shvatila važnost masovnih medija u oblikovanju mišljenja javnosti. Stoga je uložila velike napore u uspostavu veze s medijima koje su bile narušene za vrijeme njenog mandata državne sekretarice u kojem su je mnogi novinari optuživali za izbjegavanje odgovora na postavljena pitanja.

Slogani oba kandidata indirektno otkrivaju smjer kojim kandidati planiraju voditi glavnu svjetsku velesilu. Oba kandidata ističu slogane u bojama zastave SAD-a što se interpretira kao oblik patriotizma i ljubavi prema domovini. Iako su izabrali jednake boje, poruke koje šalju svojim sloganima nisu ni približno slične. Demokratska kandidatkinja svojim sloganom "Hillary for America" simboliziranu njeno iskustvo i posvećenost radu za državu te zapravo poručuje biračima da će nastaviti politiku prosperiteta i širenja globalnog utjecaja koju je vodio njezin prethodnik Barack Obama. Slogan Donalda Trumpa "Make America great again" nosi negativni osvrt na prethodne vlasti koje nisu zadržale državu sjajnom kao što je nekad bila. Također, inicira dojam da je upravo Donald Trump osoba koja će vratiti stari ugled Sjedinjenim Američkim Državama.



Slika 11. Slogani kandidata na predsjedničkim izborima u SAD-u u 2016. godini

Izvor: <https://www.quora.com/What-are-the-official-campaign-slogans-for-Hillary-Clinton-Bernie-Sanders-Donald-Trump-and-Ted-Cruz-serious-answers-only-please>

Njihova stajališta oko važnih državnih pitanja su također dijametralno suprotna. Hillary Clinton je liberalna političarka koja podržava pravo na abortus i istospolne brakove te afirmativnu akciju za manjine i žene. Također je protiv pretjeranog uplitanja religije u javnu sferu života. Donald Trump je znatno konzervativniji što se tiče prava i sloboda građana. Zalaže se za očuvanje tradicionalne američke porodice te je protiv istospolnih brakova. Njegova stajališta najbolje prikazuje njegova izjava kako ni on ni SAD nemaju vremena za političku korektnost. Najveću pažnju je posvetio očuvanju Drugog amandmana koji propisuje da svaki građanin ima pravo posjedovati i nositi vatreno oružje, dok se njegova protukandidatkinja zalaže za kontrolu prava na posjedovanje i nošenje oružja.

Unutrašnja politika kandidata izazvala je najviše reakcija u javnosti. Hillary Clinton je promovirala umjerenu politiku zasnovanu na nastavku dosadašnje politike Baracka Obame. Podupire nastavak razvijanja Obamacare-a, promjenu kaznene politiku kroz uvođenje alternativnih sankcija i reformu obavezne minimalne kazne te je skeptična povodom pitanja legalizacije marihuane i lakih droga. Donald Trump žestoki je protivnik Obamacare-a. Smatra da je Obamacare preopteretio američku ekonomiju te da ga treba ukinuti i ponovno uvesti principe slobodnog tržišta. Također se zalaže za sveobuhvatnu reformu Veteranske administracije, ali najkontroverznija tema kojom je podijelio javnost bila je tema imigracijske politike. Njegov plan podrazumijeva značajno pooštavanje imigracijske politike. Predlaže izgradnju zida duž cijele granice s Meksikom, stroža pravila prilikom izdavanja viza te ukidanje automatskog dobivanja državljanstva za novorođenčad. Također se zalaže za automatsko pretjerivanje svih stranaca koji su u SAD-u optuženi za kazneno djelo. Najradikalniji prijedlog republikanskog kandidata, uz izgradnju zida na granici s Meksikom, je zabrana ulaska osobama islamske vjeroispovijesti na područje Sjedinjenih Američkih Država. Upravo izjave o imigracijskoj politici potaknule su masovne prosvjede diljem SAD-a. Hillary Clinton podržava liberalniju imigracijsku politiku, odnosno “politiku otvorenih vrata“.

Stajališta Hillary Clinton oko ekonomske politike su uvođenje progresivne stope poreza s naglaskom na značajno veće poreze za najbogatije Amerikance sa zaradom od preko 250 000 \$ godišnje te podržavanje trgovinskih sporazuma TTP (Transpacifičko trgovinsko partnerstvo) i TTIP (Transatlantsko trgovinsko i investicijsko partnerstvo).

Donald Trump se, naprotiv, oštro protivi trgovinskim sporazumima koje smatra lošim dogovorom za SAD. Porezna politika mu je bazirana na pojednostavljivanju poreznog sustava te uvođenje poreznih olakšica za srednji stalež. Glavni cilj svog mandata naveo je povratak kapitala i proizvodnje u SAD te otvaranje radnih mjesta. Zbog toga predlaže uvođenje obaveznog prioritetnog zapošljavanja za domaće radnike te ukidanje poreza na nasljeđe.

Hillary Clinton mnogo je iskusnija kandidatkinja u pogledu vanjske politike države. Ona pripada skupini pobornika američkog intervencionizma. Podupire američku intervenciju u Iraku, naoružavanje manje radikalnih pobunjenika u Siriji te jaču suradnju sa saveznicima u Europi i zajednički odgovor na rast Rusije. Donald Trump naglasak stavlja na odnos SAD-a s Kinom. Smatra da Kina ne poštuje globalna ekonomska i trgovinska pravila te je potrebno promijeniti način suradnje između dvije države. Protivnik je politike američkog intervencionizma te planira zaokret u odnosima s Rusijom, kao i ograničavanje nepotrebnih ratnih intervencija.

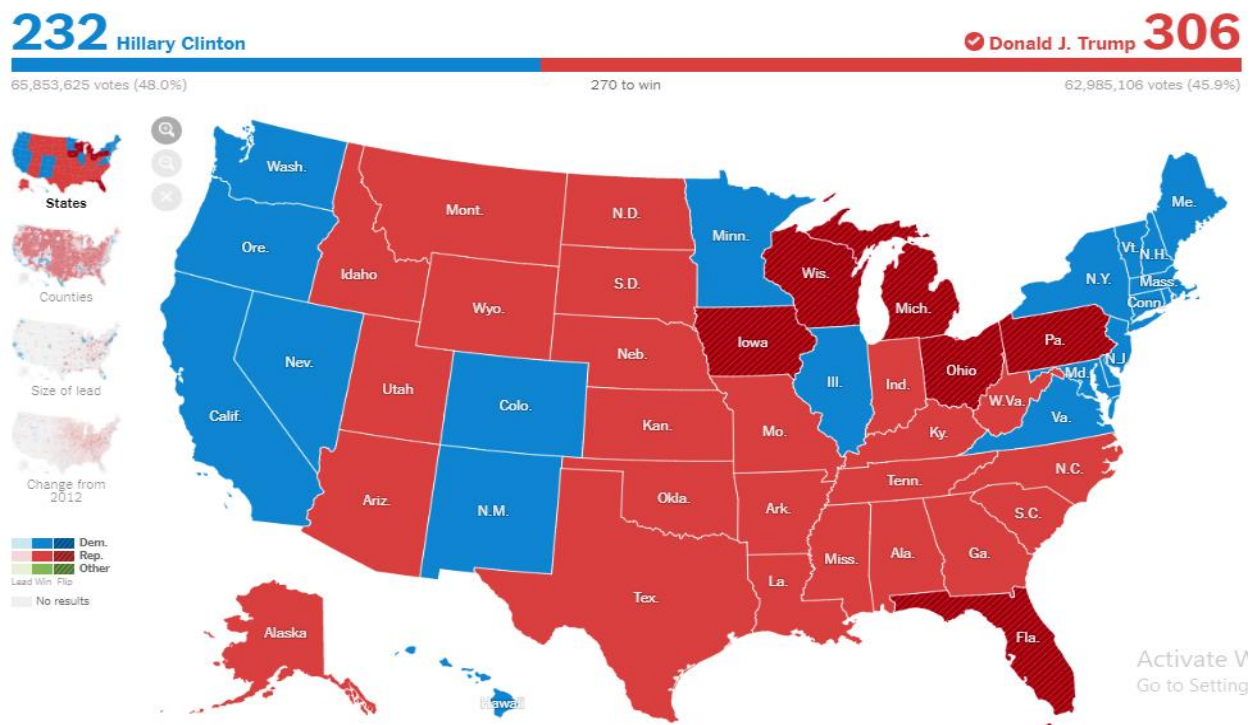
Zbog velikog utjecaja na gotovinske tijekove velikih korporacija te na cjelokupnu svjetsku ekonomiju, kandidati primaju ogromne donacije od određenih interesnih skupina čiji profit nije indiferentan na rezultate izbora. Najveći doprinos kampanji Hillary Clinton su individualne donacije, a odmah zatim slijede hedge fondovi, velike banke te ostala financijska poduzeća s doniranih oko 50 milijuna dolara. Također, veliki donatori Demokratske stranke su odvjetnička poduzeća, industrija zabave i neprofitni sektor. Značajnu financijsku podršku dobila je od bogatih individualaca iz Silicijske doline koji su joj donirali oko 120 milijuna američkih dolara. Sveukupno je prikupila 1,2 bilijuna američkih dolara što je manje od Baracka Obame 2012. godine (Allison, Harris, Rojanasakul, Sam, 2016.).

Donald Trump je svoju kampanju otpočeo zasnovao na činjenici da je milijunaš i da nije ovisan o velikim donacijama različitih interesnih skupina. Spomenuta činjenica je predstavljala veliku prednost republikanskog kandidata u odnosu na Hillary Clinton koju je optužio da je taoc velikih korporacija. Na predizbornu kampanju je potrošio svojih 66 milijuna dolara, dok je najviše donacija prikupio od malih individualnih donatora (200\$ ili manje), oko 280 milijuna dolara. Ukupan iznos koji je prikupio tijekom kampanje iznosi 646,8 milijuna američkih dolara (Allison, Harris, Rojanasakul, Sam, 2016.).

Većina američkih i svjetskih medija okarakterizirala je kampanje predsjedničkih kandidata “najprljavijima u povijesti“. Kandidati su se orijentirali na međusobne optužbe i svađe što je medijski bilo zanimljivije od predstavljanja programa, ali je također okarakterizirano kao kontraproduktivno kod glasača. Tri sučeljavanja koja su se održala neposredno prije izbora, 26. rujna te 9. i 19. listopada, poslužila su kandidatima kao prilika za verbalni obračun te su u potpunosti zanemarila glavnu svrhu sučeljavanja, predstavljanje i usporedba vlastitih programa s protukandidatovima. Činjenica da su prije spomenutih sučeljavanja po svim anketama javnog mišljenja bili izjednačeni, dodatno je pogoršala kvalitetu debata. Većina svjetskih analitičara se složila da je iz nekvalitetnih sučeljavanja Hillary Clinton izašla kao pobjednica, ali naglašavaju da je razlog neprimjerena retorika republikanskog kandidata, a ne kvaliteta njezine komunikacije. Upravo su zbog toga američki i svjetski mediji procijenili šanse Donalda Trumpa za pobjedu na predsjedničkim izborima minimalnima te su očekivali relativno laganu pobjedu demokratske kandidatkinje.

3.2.2. Utjecaj predsjedničkih izbora na američko tržište kapitala


8. studenog 2016. godine održani su 58. izbori za predsjednika Sjedinjenih Američkih Država. Ukupno 225 milijuna američkih državljana imalo je pravo glasa. Neočekivanu pobjedu odnio je republikanski kandidat Donald Trump te postao 45. predsjednik SAD-a. Od mogućih 538 elektorskih glasova Trump je osvojio 306, odnosno 57%, dok je demokratska kandidatkinja osvojila 232 elektorskih glasova, odnosno 42%. Odaziv birača je bio oko 54%. Međutim, dogodio se slučaj koji je odavno prepoznat kao najveći nedostatak indirektnog izbora predsjednika. Iako je Donald Trump osvojio više elektora, Hillary Clinton je osvojila veću ukupnu potporu birača. Čak 2,9 milijuna Amerikanaca više je glasalo za demokratsku kandidatkinju u odnosu na protukandidata, što predstavlja 2,1% razlike u korist Hillary Clinton. Ukupno je za Clinton glasovalo 65 853 625 birača, odnosno 48.0%, dok je za Trumpa glasovalo 62 985 106 birača, odnosno 45.9%. Upravo zbog elektorskog načina izbora predsjednika, dogodio se svojevrsni paradoks koji se ogleda u činjenici da je predsjednik Sjedinjenih Američkih Država postao kandidat s dobivenom manjom potporom od strane birača. Na slici 12 su prikazani rezultati predsjedničkih izbora po saveznm državama.



Slika 12. Rezultati predsjedničkih izbora u SAD-u 2016. godine

Izvor: <https://www.nytimes.com/elections/results/president>

Na prikazanoj karti SAD-a crvenom bojom su označene savezne države koje su glasale za Donalda Trumpa, dok su plavom bojom označene savezne države koje su podržale kandidaturu Hillary Clinton. Primjetna je dominacija crvene boje, ali bitnija od zastupljenosti je njezina raspoređenost. Iako je Hillary Clinton osvojila 2 od 4 najmnogoljudnije savezne države (Kalifornija i New York), pobjedu Republikanskoj stranci su donijele države koje su na prošlim predsjedničkim izborima iskazale većinsku podršku Demokratima. Savezne države koje su napravile politički zaokret u odnosu na predsjedničke izbore 2012. godine ("flip" države) su označene tamnocrvenom bojom te su poredane po značaju, odnosno broju elektorskih glasova, od države s najviše stanovnika prema državi s najmanje stanovnika: Florida (29 elektora), Pennsylvania (20), Ohio (18), Michigan (16), Wisconsin (10) i Iowa (6). Upravo su navedene savezne države bile presudan čimbenik u predsjedničkoj utrci Donalda Trumpa i Hillary Clinton, ali također je potrebno napomenuti da su pobjede bile tijesne, s manje od 2% razlike između kandidata te manje od 50% izglasane podrške u većini "flip" država. S ukupnih 99 elektorskih glasova koje su mu donijele spomenute države, Donald Trump je prešao granicu od 270 elektorskih glasova koliko je potrebno za pobjedu na predsjedničkim izborima.



Slika 13. Rezultati predsjedničkih izbora prema različitim parametrima

Izvor: <https://www.nytimes.com/interactive/2016/11/08/us/politics/election-exit-polls.html>

Slika 13 prikazuje rezultate glasovanja među biračima različitog spola, rase, godina te stupnja obrazovanja. Pripadnici muškog spola iskazali su većinsku podršku od 53% Republikanskoj stranci, što je za 5% više nego na izborima 2012. godine. Naprotiv, pripadnice ženskog spola s 54% podrške favoriziraju Demokratsku stranku, što je 1% više nego 2012. godine. Rezultati potpore pojedinom kandidatu s obzirom na rasnu pripadnost su očekivani s obzirom na različite perspektive buduće imigracijske politike SAD-a. Iako je Donald Trump dobio ispodpolovičnu potporu od svih rasa osim bijele (58%), kod svih rasa je izraženo povećanje potpore Republikanskoj stranci u usporedbi s prošlim predsjedničkim izborima. Dva su moguća razloga za takav napredak: uspješna kampanja Donalda Trumpa koja je doprijela do velikog broja birača ili podbačaj kampanje Hillary Clinton koja je izgubila prednost u odnosu na republikance koju je stvorio Barack Obama. Glasovi prema starosnoj dobi su ravnomjerno raspoređeni. Većina punoljetnih građana mlađih od 45 godina podržava politiku Hillary Clinton, dok većina građana starijih od 44 godine podržava politiku Donalda Trumpa. U slučaju rezultata prema stupnju obrazovanja Donald Trump ima blagu premoć kod osoba nižeg stupnja od sveučilišnog obrazovanja, dok podrška Hillary Clinton raste proporcionalno sa stupnjem sveučilišnog obrazovanja. Iz navedenog se može zaključiti da je postotak pobornika Donalda Trumpa najveći kod muških pripadnika bijele rase starijih od 44 godine te nižim stupnjem obrazovanja.

Neočekivan rasplet predsjedničkih izvora šokirao je Wall Street. Mnogi su investitori očekivali pobjedu Hillary Clinton te su bili potpuno nespremni na drugačiji ishod. Rezultati izbora izazvali su histeričnu reakciju Wall Street-a s obzirom da ga je većina analitičara smatrala nepredvidljivim političarom. Predviđanja su, u slučaju pobjede Donalda Trumpa, bila pad američkih tržišnih indeksa te potencijalno negativan utjecaj na američko gospodarstvo. Najveća opasnost se predviđala poduzećima koja su usko povezana s kineskim i meksičkim tržištem zbog najava republikanskog kandidata da će u slučaju pobjede povećati carinu na uvoz robe iz spomenutih zemalja.

Što je pobjeda Donalda Trumpa bila izvjesnija, rasprodaja na tržištu kapitala je bila aktivnija. Mnogi investitori su odlučili prebaciti svoja ulaganja u manje rizične investicije upravo zbog nesigurnosti na tržištu uzrokovane novoizabranim predsjednikom. Pobjeda Republikanske stranke na Floridi, koja je proglašena ključnom saveznom državom u utrci za predsjednika, proizvela je lančanu reakciju te pojačala pad ključnih američkih indeksa. Dow Jones, najpoznatiji svjetski indeks, pao je za 4,13% , odnosno više od 800 bodova. S&P 500, indeks koji najbolje prezentira stanje u američkom gospodarstvu, suočio se s padom za 99,25 bodova što predstavlja 4,65%. Treći najznačajniji američki indeks NASDAQ Composite također je pretrpio velike gubitke. Zabilježen je njegov pad od 4,6%, odnosno 221 bod (Golding, 2016.). Investitori su se ubrzano povlačili iz rizičnih investicija poput dionica te prebacivali svoja ulaganja u sigurnije investicije kao što su zlato i obveznice. Značajno povećanje potražnje uzrokovalo je povećanje cijena zlata za 48 dolara po unci zlata, odnosno 3,8% i cijena obveznica za 4,6% što je najčešće pokazatelj krize i nesigurnosti na tržištu. Chris Weston, glavni tržišni strateg burze u Melbourneu, izjavio je: "Anketari trebaju otići na odmor - svaki od njih bi trebao dobiti otkaz. Tržišta nisu bila spremna na ovo." aludirajući na američke ankete koje su davale prednost Hillary Clinton neposredno prije izbora (Denyer, Mui, 2016.). Mnogi analitičari prognozirali su da će politika izolacionizma, bez obzira na većinsko prihvatanje kod birača, imati značajne negativne posljedice za gospodarstvo SAD-a. Iako je Donald Trump obećao veliko smanjenje poreza za pojedince i korporacije, jedna od najvećih svjetskih rejting agencija Moody's prognozirala je da će se, zbog povlačenja iz dugogodišnjih trgovinskih sporazuma te povećanja carine na uvoz robe iz Kine i Meksika, broj radnih mjesta smanjiti za 3,5 milijuna te će nezaposlenost porasti za 7% do kraja njegovog mandata. Također, povećana je mogućnost recesije u SAD-u u 2018. godini.

Unatoč svim predviđanjima, nakon pobjedničkog govora Donalda Trumpa dogodio se novi obrat. U svom govoru pozvao je na zajedništvo i suradnju u izgradnji boljih Sjedinjenih Američkih Država. Očito su riječi Donalda Trumpa osvijestile investitore te ih potaknule da se usredotoče na program Republikanske stranke te na industrijske sektore kojima taj program pogoduje. Tržište se počelo naglo oporavljati, a najveći su dobitnici industrijska, energetska, financijska i farmaceutska poduzeća, odnosno sektori koji bi trebali najviše profitirati od predloženih reformi novog predsjednika. Glavni razlog su najavljene reforme poput smanjenja poreza, poticanje rasta američkih poduzeća te popuštanje restrikcija za banke među kojima je i opoziv Dodd-Frank zakona kojem su se banke svojedomno protivile. Tri najvažnija indeksa u SAD-u su, nakon prvotnog pada preko 4%, anulirali gubitak te su kraj dana dočekali s rastom većim od 1%. Dow Jones indeks je završio dan s rastom od 1,4%, dok su S&P 500 i NASDAQ Composite zabilježili jednak rast od 1,11%. Zdravstvena poduzeća najveći su gubitnici izbora na tržištu. Najave o ukidanju Obamacare-a značajno su pogodile zdravstveni sektor u kojem su se neka poduzeća suočila s padom cijene dionica od čak 17%.

Sljedeći dan pozitivan utjecaj rezultata izbora se nastavio. Dow Jones je rastom od 1,17% dostigao rekordnih 18 807 bodova ponajprije zahvaljujući financijskom sektoru koji je porastao dodatnih 3,7% (Kralj, 2016.). U dva dana otkako je Donald Trump pobijedio na izborima financijski sektor porastao je za 7,9% te dosegao najvišu razinu od financijske krize iz 2008. godine. S&P 500 je također porastao za 0,2%, odnosno 2167 bodova. Naprotiv, NASDAQ Composite indeks je pao na 5 208 bodova što predstavlja pad od 0,81%. Uzrok slabljenja indeksa je značajan udio tehnoloških poduzeća u njegovom sastavu koje su doživjele oštar pad. Cijena dionice Apple-a pala je 2,8%, cijena dionice Amazona 3,8% pa je S&P indeks tehnološkog sektora pao za ukupno 1,6%. Obujam je, u oba dana trgovanja nakon izbora, bio znatno iznad prosjeka. Na američkim burzama trgovalo se s 12,3 milijarde dionica po danu, dok je prosječni dnevni obujam u posljednjih 20 dana iznosio 7,3 milijarde.

Slična situacija na tržištu (povećana volatilnost, velik pad pa nagli oporavak tržišta) se dogodila i nakon Brexita. Ankete uoči referendumu predviđale su ostanak Ujedinjenog Kraljevstva u Europskoj Uniji, a dogodilo se upravo suprotno što je također izazvalo panične reakcije investitora koji su se počeli rješavati rizičnih investicija. S obzirom da su se ubrzo stabilizirala, nameće se zaključak da su tržišta osjetljivija na iznenađenja nego na rezultat političkih događaja.

3.2.3. Utjecaj predsjedničkih izbora na ostala svjetska tržišta kapitala

S obzirom da je New York u SAD-u najvažnije svjetsko financijsko središte, značajan politički događaj poput predsjedničkih izbora ne može proći neprimijećeno na ostalim svjetskim tržištima. Svjetska tržišta kapitala su globalizirana što omogućuje dostupnost informacijama bez obzira na lokaciju te je očito da izbor predvodnika najsnažnije svjetske ekonomske velesile mora imati veliki utjecaj na sva svjetska tržišta kapitala. Investitori u ostatku svijeta također su očekivali pobjedu Hillary Clinton te se nesigurnost zbog neočekivane pobjede Donalda Trumpa vrlo brzo proširila na sve svjetske burze.

Što je pobjeda republikanskog kandidata postajala izvjesnija, nesigurnost među svjetskim investitorima je rasla. Najbrže su reagirala azijska tržišta pa je tako indeks burze u Tokiju, NIKKEI 225, izgubio vrijednost u iznosu od 5,4%, dok je Hang Seng indeks u Hong Kongu pao za 2,8%. Južnokorejski tržišni indeks Kospi pao je za 2,5%, kineski Shanghai Composite 1%, a australski ASX 200 za 2,1% (Gara, 2016.). Nakon otvaranja europskih tržišta panika se proširila i na europske investitore. STOXX 600, paneuropski indeks sastavljen od 600 europskih poduzeća iz 17 različitih zemalja, zabilježio je pad od 2,4%. Londonski tržišni indeks FTSE 100 pao je oko 1,8%, dok su pariški CAC 40 indeks te frankfurtski DAX 30 zabilježili pad preko 2%. Najveći utjecaj rezultata predsjedničkih izbora na tržištu novca zabilježen je u kretanju meksičke valute. Meksički peso pao je za više od 13%, što je najveći dnevni pad u posljednja dva desetljeća. Uzrok oštrom padu je strah ulagača da će trgovinska politika kakvu je najavio novi predsjednik SAD-a znatno naštetiti meksičkom gospodarstvu koje ovisi o izvozu u SAD.

Panika na tržištu trajala je znatno kreće nego u slučaju Brexita te su se svjetska tržišta počela stabilizirati neposredno nakon američkog. Nakon početne panike i oštrog pada japanski NIKKEI 225 narastao je za 6,9% te dosegao 17 367 bodova, dok je Hang Seng, tržišni indeks Hong Konga zabilježio rast od 1,9%. Australski ASX 200 također se brzo oporavio te je nakon jednodnevnog pada narastao za 3,34% te dosegao 5 328 bodova (Thuy, 2016.). I europske burze zabilježile su nagli oporavak nakon početnog šoka. STOXX 600 indeks narastao je za 1,5%, a londonski indeks FTSE 100 zatvaranje burze dočekao je na 6 911 bodova što je rast od 1%. Njemački DAX 30 skočio je za 1,56%, na 10 646 bodova, dok je francuski CAC 40 narastao za 1,49%, dosegnuvši 4 543 boda. Brz i efikasan oporavak svjetskih tržišta kapitala demantirao je prognoze većine analitičara te dokazao otpornost tržišta na nepredviđene situacije.

4. FORMIRANJE PORTFELJA NA TRŽIŠTU KAPITALA

4.1. Dionice u sastavu portfelja

S ciljem testiranja što reprezentativnijeg uzorka, odabrano je 20 dionica američkih poduzeća s velikom tržišnom kapitalizacijom iz 10 različitih sektora. Svi sektori su jednako zastupljeni u portfelju, odnosno iz svakog sektora odabrana su po 2 poduzeća kako bi se analiziralo realno stanje na tržištu kapitala prije i poslije predsjedničkih izbora. Sektori su podijeljeni prema TRBC industrijskoj klasifikaciji (Thomas Reuters Business Classification). Odabrane dionice raspoređene po sektorima prikazane su u tablici 2.

Tablica 2. Odabrane dionice s Wall Street-a po sektorima

SEKTOR	IME PODUZEĆA	SIMBOL DIONICE
BASIC MATERIALS	LYONDELLBASELL INDUSTRIES N.V.	LYB
	WESTROCK CO.	WRK
CONSUMER CYCLICALS	GENERAL MOTORS CO.	GM
	WALT DISNEY CO.	DIS
CONSUMER NON-CYCLICALS	COCA COLA CO.	KO
	PROCTER & GAMBLE CO.	PG
ENERGY	CHEVRON CORP.	CVX
	EXXON MOBIL CORP.	XOM
INDUSTRIALS	CATERPILLAR INC.	CAT
	FEDEX CORP.	FDX
FINANCIALS	JPMORGAN CHASE & CO.	JPM
	CITIGROUP INC.	C
HEALTHCARE	JOHNSON & JOHNSON	JNJ
	CVS HEALTH CORP.	CVS
TECHNOLOGY	APPLE INC.	AAPL
	MICROSOFT CORP.	MSFT
TELECOMMUNICATIONS	AT&T INC.	T
	VERIZON COMMUNICATIONS INC.	VZ
UTILITIES	NEXTERA ENERGY INC.	NEE
	AMERICAN WATER WORKS CO. INC.	AWK

Izvor: The Center for Research in Security Prices (CRSP)

Analiza obuhvaća dnevne podatke odabranih dionica u vremenskom razdoblju od 1 godine prije predsjedničkih izbora te 1 godine nakon izbora Donalda Trumpa za predsjednika SAD-a, isključujući tjedan u kojem su održani izbori. Tablica 2 prikazuje poduzeća čije su dionice sastavnice analiziranog portfelja te njihovu raspodjelu po sektorima. TRBC klasifikacija je najopsežnija i najdetaljnija industrijska klasifikacija na tržištu. Odabir 20 dionica ravnomjerno raspoređenih u 10 različitim sektorima predstavlja uzorak namijenjen simuliranju kretanja ukupnog tržišta. Upravo širok raspon sektora zastupljenih u portfelju osigurava reprezentativnost i vjerodostojnost analize tržišta.

Jedan od najvažnijih doprinosa Markowitzeva teorija portfelja, upravo je promatranje korelacije između vrijednosnica. Na sljedećoj slici prikazani su koeficijenti korelacije između dionica koje sačinjavaju promatrani portfelj u razdoblju prije predsjedničkih izbora.

	LYB	WRK	GM	DIS	KO	PG	CVX	XOM	CAT	FDX	JPM	C	JNJ	CVS	AAPL	MSFT	T	VZ	NEE	AWK
LYB	1																			
WESTROCK	0.454	1																		
GM	0.434	0.431	1																	
W. DISNEY	0.422	0.409	0.477	1																
COCA COLA	0.272	0.240	0.261	0.426	1															
P&G	0.218	0.268	0.278	0.418	0.631	1														
CHEVRON	0.537	0.337	0.426	0.444	0.397	0.415	1													
EXXON	0.508	0.322	0.304	0.450	0.360	0.400	0.780	1												
CATERPILLAR	0.640	0.521	0.542	0.485	0.281	0.309	0.597	0.548	1											
FEDEX	0.494	0.473	0.496	0.505	0.430	0.385	0.446	0.401	0.518	1										
JPMORGAN	0.551	0.516	0.579	0.545	0.392	0.460	0.550	0.524	0.583	0.592	1									
CITIGROUP	0.557	0.575	0.619	0.566	0.310	0.394	0.482	0.464	0.612	0.601	0.919	1								
J&J	0.269	0.237	0.327	0.438	0.417	0.531	0.469	0.445	0.310	0.361	0.482	0.412	1							
CVS	0.191	0.186	0.210	0.331	0.391	0.306	0.245	0.267	0.241	0.262	0.365	0.354	0.313	1						
APPLE	0.352	0.247	0.364	0.394	0.252	0.304	0.313	0.287	0.398	0.331	0.463	0.450	0.302	0.289	1					
MICROSOFT	0.399	0.397	0.461	0.447	0.438	0.414	0.431	0.315	0.411	0.462	0.559	0.548	0.405	0.407	0.505	1				
AT&T	0.209	0.214	0.296	0.348	0.517	0.488	0.418	0.384	0.329	0.358	0.284	0.228	0.449	0.300	0.276	0.303	1			
VERIZON	0.274	0.271	0.283	0.352	0.500	0.452	0.426	0.405	0.314	0.370	0.333	0.280	0.455	0.349	0.237	0.345	0.823	1		
NEXTERA	0.041	0.102	0.041	0.193	0.535	0.421	0.181	0.175	0.090	0.239	0.096	0.004	0.326	0.277	0.113	0.220	0.508	0.498	1	
AWWC	-0.017	0.114	0.009	0.116	0.468	0.402	0.173	0.187	0.047	0.179	0.021	-0.025	0.293	0.267	0.132	0.248	0.464	0.443	0.675	1

Slika 14. Korelacija odabranih dionica u razdoblju prije predsjedničkih izbora

Izvor: Izračun autora

Promatrajući prinose dionica 1 godinu prije izbora, najveći je koeficijent korelacije unutar financijskog sektora, odnosno između prinosa Citigroup Inc. i JP Morgan Chase & Co. dionica te iznosi 0,919. Visok iznos korelacije označava identičan smjer kretanja prinosa unutar financijskog sektora u većini slučajeva. Dakle, pozitivan prinos Citigroup Inc. najčešće je praćen s pozitivnim kretanjem JP Morgan Chase & Co., i obrnuto.

Najmanji koeficijent korelacije u spomenutom razdoblju posjeduje odnos između prinosa Citigroup Inc. i American Water Works Co. Inc. u iznosu od -0,025 što znači da je veća vjerojatnost da će kretanje prinosa ovih dionica biti u suprotnom smjeru. Malen iznos negativne korelacije označava slabu povezanost kretanja cijena spomenutih dionica.

Slika 15 prikazuje korelaciju istih dionica, ali u razdoblju nakon predsjedničkih izbora.

	LYB	WRK	GM	DIS	KO	PG	CVX	XOM	CAT	FDX	JPM	C	JNJ	CVS	AAPL	MSFT	T	VZ	NEE	AWK
LYB	1																			
WESTROCK	0.259	1																		
GM	0.282	0.290	1																	
W. DISNEY	0.140	0.178	0.267	1																
COCA COLA	-0.078	0.154	0.100	0.077	1															
P&G	0.053	0.091	0.061	0.102	0.404	1														
CHEVRON	0.423	0.173	0.236	0.054	0.116	0.145	1													
EXXON	0.288	0.167	0.168	0.093	0.141	0.230	0.598	1												
CATERPILLAR	0.357	0.273	0.268	0.110	0.036	0.163	0.298	0.298	1											
FEDEX	0.320	0.352	0.209	0.071	0.064	0.076	0.155	0.233	0.388	1										
JPMORGAN	0.372	0.394	0.343	0.193	-0.068	-0.030	0.320	0.280	0.407	0.397	1									
CITIGROUP	0.362	0.384	0.384	0.213	-0.069	-0.015	0.335	0.308	0.384	0.370	0.817	1								
J&J	-0.013	0.005	0.017	-0.033	0.101	0.185	0.054	0.172	-0.015	0.126	0.028	0.041	1							
CVS	0.085	0.031	0.170	0.125	0.184	0.091	0.110	0.032	0.124	0.167	0.123	0.115	0.051	1						
APPLE	0.139	0.214	0.063	0.064	0.046	0.058	-0.015	0.056	0.133	0.211	0.193	0.188	0.042	-0.008	1					
MICROSOFT	0.054	0.210	0.049	0.096	0.115	0.084	-0.100	0.103	0.233	0.412	0.194	0.194	0.156	-0.064	0.453	1				
AT&T	0.047	0.080	0.212	0.341	0.270	0.188	0.181	0.181	0.092	0.044	0.129	0.175	0.090	0.122	0.054	0.083	1			
VERIZON	-0.014	0.066	0.164	0.258	0.249	0.199	0.167	0.166	0.088	0.015	0.072	0.081	0.173	0.156	-0.059	0.077	0.665	1		
NEXTERA	-0.155	0.046	-0.029	-0.019	0.358	0.231	-0.051	-0.018	-0.044	0.079	-0.302	-0.300	0.232	-0.021	0.083	0.189	0.169	0.168	1	
AWWC	-0.064	0.055	0.040	-0.001	0.345	0.295	0.133	0.133	-0.011	0.099	-0.201	-0.174	0.229	-0.016	0.011	0.182	0.202	0.203	0.533	1

Slika 15. Korelacija odabranih dionica u razdoblju nakon predsjedničkih izbora

Izvor: Izračun autora

U razdoblju nakon predsjedničkih izbora, kod većine dionica unutar portfelja, primjetno je smanjenje koeficijenata korelacije u usporedbi s razdobljem prije izbora. Najveći je koeficijent korelacije ostao unutar financijskog sektora, između dionica Citigroup Inc. i JP Morgan Chase & Co., ali u manjem iznosu nego u razdoblju prije izbora (0,817). Najmanji koeficijent korelacije odnosi se na prinose između dionice NextEra Energy Inc. i dionica iz financijskog sektora. S dionicom JP Morgan Chase & Co. koeficijent korelacije iznosi -0,302, dok je s dionicom Citigroup Inc. taj iznos jednak -0,300.

4.2. Izračun mjera rizika za promatrane dionice

Rizičnost ulaganja na tržištu kapitala analizirana je testiranjem rizika odabranog portfelja korištenjem najpoznatijih mjera rizika, beta koeficijenta i rizičnost vrijednosti (VaR). Beta pokazuje koeficijent osjetljivosti dionice pojedinog poduzeća na kretanja tržišta te predstavlja iznos u kojem se vrijednosnica povećava ili smanjuje za 1% promjene kretanja tržišta (Bodie, Kane, Marcus, 2014., str. 260). Ukoliko je beta pojedine dionice veća od 1, prinos dionice varira više od tržišnog prinosa dok beta koeficijent manji od 1 označava variranje prinosa dionice u manjem iznosu od tržišnog, dakle manji sustavni rizik. Beta koeficijent jednak 1 označava proporcionalno kretanje prinosa dionice s prinosima tržišta. Najčešće korišteni predstavnik tržišnog kretanja je S&P 500 indeks koji se koristi i u ovom diplomskom radu. Izračunati su beta koeficijenti u jednako ponderiranom portfelju u oba razdoblja te su prikazani u tablicama 3 i 4.

Tablica 3. Beta koeficijent za portfelj prije predsjedničkih izbora

SEKTOR	IME PODUZEĆA	BETA	BETA (IND)	BETA (P)
BASIC MATERIALS	LYONDELLBASELL	1.35	1.49	0.98
	WESTROCK	1.62		
CONSUMER CYCLICALS	GENERAL MOTORS	1.09	1.00	
	WALT DISNEY	0.90		
CONSUMER NON-CYCLICALS	COCA COLA	0.60	0.60	
	PROCTER & GAMBLE	0.61		
ENERGY	CHEVRON	1.21	1.05	
	EXXON	0.89		
INDUSTRIALS	CATERPILLAR	1.31	1.27	
	FEDEX	1.23		
FINANCIALS	JP MORGAN CHASE	1.44	1.63	
	CITIGROUP	1.82		
HEALTHCARE	JOHNSON & JOHNSON	0.60	0.66	
	CVS HEALTH	0.72		
TECHNOLOGY	APPLE	1.05	1.12	
	MICROSOFT	1.20		
TELECOMMUNICATIONS	AT&T	0.53	0.57	
	VERIZON	0.61		
UTILITIES	NEXTERA ENERGY	0.38	0.38	
	AMERICAN WATER WORKS	0.37		

Izvor: Izračun autora

U tablici 3 su prikazani beta koeficijenti odabranih dionica, njihovih industrija te jednako ponderiranog portfelja u razdoblju od 1 godine prije predsjedničkih izbora.

Najveći sustavni rizik posjeduju dionice Citigroup Inc. i Westrock Co. s beta koeficijentima od 1,82 i 1,62. Najveći beta koeficijent među sektorima je koeficijent financijskog sektora u iznosu od 1,63 što znači da prinosi dionica financijskog sektora imaju veći sustavni rizik od dionica iz ostalih sektora, odnosno variraju u značajno većem iznosu od tržišnog indeksa.

Najmanji sustavni rizik posjeduju dionice American Water Works Co. Inc. i NextEra Energy Inc. što ih s beta koeficijentima od 0,37 i 0,38 čini najsigurnijim dionicama odabranog portfelja u razdoblju prije predsjedničkih izbora. Prinosi spomenutih dionica variraju u značajno manjem iznosu od tržišnog indeksa. Dakle, sektor čiji prinosi najmanje variraju u odnosu na tržišni indeks je komunalni sektor (Utilities) s beta koeficijentom od 0,38.

Portfelj sastavljen od jednakog udjela svih 20 dionica posjeduje beta koeficijent u iznosu od 0,98 što znači da ima neznatno manji sustavni rizik od tržišnog indeksa. Odnosno, prinos tržišnog indeksa varira slično kao i jednako ponderirani portfelj sastavljen od 20 odabranih dionica.

Tablica 4. Beta koeficijent za portfelj poslije predsjedničkih izbora

SEKTOR	IME PODUZEĆA	BETA	BETA (IND)	BETA (P)
BASIC MATERIALS	LYONDELLBASELL	1.23	1.36	0.90
	WESTROCK	1.49		
CONSUMER CYCLICALS	GENERAL MOTORS	1.36	0.99	
	WALT DISNEY	0.61		
CONSUMER NON-CYCLICALS	COCA COLA	0.33	0.37	
	PROCTER & GAMBLE	0.40		
ENERGY	CHEVRON	0.64	0.65	
	EXXON	0.67		
INDUSTRIALS	CATERPILLAR	1.40	1.40	
	FEDEX	1.40		
FINANCIALS	JP MORGAN CHASE	1.36	1.46	
	CITIGROUP	1.55		
HEALTHCARE	JOHNSON & JOHNSON	0.47	0.51	
	CVS HEALTH	0.54		
TECHNOLOGY	APPLE	1.30	1.30	
	MICROSOFT	1.30		
TELECOMMUNICATIONS	AT&T	0.75	0.68	
	VERIZON	0.62		
UTILITIES	NEXTERA ENERGY	0.19	0.31	
	AMERICAN WATER WORKS	0.44		

Izvor: Izračun autora

U tablici 4 prikazani su beta koeficijenti odabranih dionica, njihovih industrija te jednako ponderiranog portfelja u razdoblju od 1 godine nakon predsjedničkih izbora.

Najrizičnija dionica, u razdoblju 1 godine nakon predsjedničkih izbora u SAD-u, je Citigroup Inc, identično kao i u razdoblju prije izbora. Beta koeficijent u iznosu od 1,55 predstavlja veći sustavni rizik u usporedbi s tržišnim indeksom, odnosno prinosi dionice Citigroup Inc. variraju više od prinosa tržišnog indeksa, ali također predstavlja smanjenje sustavnog rizika dionice u odnosu na razdoblje prije predsjedničkih izbora ($1,55 < 1,82$). Financijski sektor je, i u razdoblju nakon izbora, sektor s najvećim prosječnim beta koeficijentom u iznosu od 1,46 što ga čini najosjetljivijim sektorom u odnosu na tržišna kretanja.

Jednako kao i u prethodnom razdoblju, prinosi dionica komunalnog sektora najmanje su osjetljivi na tržišna kretanja. Najmanji beta koeficijent u iznosu od 0,19 ima dionica NextEra Energy Inc. što je manji iznos nego u razdoblju prije izbora ($0,19 < 0,38$). Dakle, prinose spomenute dionice karakteriziraju vrlo mali pomaci u usporedbi s kretanjima prinosa tržišnog indeksa. Sektor s najmanjim sustavnim rizikom ponovno je komunalni sektor (Utilities) s beta koeficijentom od 0,31, ali također s primjetnim smanjenjem u odnosu na prethodno razdoblje ($0,31 < 0,38$).

Beta koeficijent jednako ponderiranog portfelja u razdoblju nakon izbora iznosi 0,90 što predstavlja smanjenje u odnosu na prethodnim razdobljem ($0,90 < 0,98$). Iako je sustavni rizik portfelja manji nakon izbora, beta koeficijenti dionice General Motors Co. te dionica iz telekomunikacijskog, tehnološkog i industrijskog sektora se povećavaju nakon izbora što onemogućava donošenje zaključka o razlici u riziku ulaganja u spomenutim razdobljima.

Nakon izračuna osjetljivosti prinosa odabranih dionica na kretanje tržišnog indeksa, izračunati su maksimalni potencijalni dnevni i mjesečni gubici s vjerojatnošću od 95% i 99%. U svrhu procjenjivanja maksimalnih gubitaka korišten je povijesni model rizične vrijednosti (VaR). Povijesni model je najjednostavniji i najrasprostranjeniji model za izračun rizične vrijednosti te činjenica da pokazuje najveći mogući gubitak za određenu razinu vjerojatnosti razlikuje ga od ostalih modela za mjerenje rizika koji pokazuju samo iznos mogućeg gubitka. Rezultati povijesnog VaR modela u oba promatrana razdoblja prikazani su u sljedeće 2 tablice.

Tablica 5. VaR odabranih dionica prije predsjedničkih izbora

DIONICE	ULOG	DNEVNI VaR				MJESEČNI VaR	
	(KN)	VaR 95%	VaR 99%	VaR 95% (KN)	VaR 99% (KN)	VaR 95% (KN)	VaR 99% (KN)
LYONDELLBASELL	100 000	-4.00%	-5.15%	-3997.18	-5145.24	-18317.40	-23578.46
WESTROCK	100 000	-3.93%	-7.04%	-3932.67	-7041.45	-18021.77	-32268.00
GENERAL MOTORS	100 000	-2.93%	-4.28%	-2927.13	-4280.68	-13413.81	-19616.52
WALT DISNEY	100 000	-1.95%	-3.94%	-1947.06	-3936.58	-8922.53	-18039.69
COCA COLA	100 000	-1.61%	-3.21%	-1607.30	-3207.40	-7365.56	-14698.16
PROCTER & GAMBLE	100 000	-1.47%	-2.30%	-1468.91	-2300.19	-6731.38	-10540.77
CHEVRON	100 000	-2.72%	-4.18%	-2722.98	-4176.31	-12478.25	-19138.24
EXXON	100 000	-2.31%	-3.43%	-2305.60	-3428.19	-10565.59	-15709.96
CATERPILLAR	100 000	-2.79%	-4.78%	-2788.13	-4776.99	-12776.82	-21890.91
FEDEX	100 000	-2.80%	-4.46%	-2799.79	-4464.06	-12830.26	-20456.88
JP MORGAN CHASE	100 000	-2.44%	-4.30%	-2440.39	-4297.93	-11183.29	-19695.57
CITIGROUP	100 000	-3.41%	-6.45%	-3410.58	-6454.05	-15629.26	-29576.19
JOHNSON & JOHNSON	100 000	-1.40%	-2.39%	-1395.83	-2390.03	-6396.49	-10952.50
CVS HEALTH	100 000	-2.23%	-3.60%	-2234.44	-3597.21	-10239.50	-16484.50
APPLE	100 000	-2.54%	-5.24%	-2538.48	-5239.12	-11632.78	-24008.67
MICROSOFT	100 000	-2.17%	-4.00%	-2174.58	-3999.33	-9965.18	-18327.21
AT&T	100 000	-1.65%	-2.73%	-1647.62	-2732.63	-7550.36	-12522.49
VERIZON	100 000	-1.61%	-3.08%	-1613.91	-3080.48	-7395.88	-14116.52
NEXTERA ENERGY	100 000	-1.79%	-2.72%	-1787.61	-2715.70	-8191.87	-12444.90
AMERICAN WATER WORKS	100 000	-1.89%	-3.99%	-1891.69	-3987.37	-8668.83	-18272.44

Izvor: Izračun autora

Tablica 5 prikazuje rizične vrijednosti prije predsjedničkih izbora. Evidentno je da se rizična vrijednost svih dionica povećava s razinom pouzdanosti analize. Na temelju rezultata povijesnog VaR modela, najrizičnija dionica unutar portfelja je dionica Lyondellbasell Industries N.V. s maksimalnim dnevnim gubicima od 4,00% uloga pri razini pouzdanosti od 95%, dok je pri razini od 99% najrizičnija dionica Westrock Co. s gubicima od 7,04%. Dakle, ukoliko bi distribucija prinosa ostala jednaka kao i u promatranom razdoblju, investitor bi na uloženi 100 000 kn u dionicu Westrock Co., uz razinu pouzdanosti od 95%, izgubio maksimalno 3 932,67 kune, dok bi mu maksimalni potencijalni gubitak pri razini pouzdanosti od 99% bio 7 041,45 kn. Ekvivalente vrijednosti na mjesečnoj razini izračunate su množenjem dnevne VaR vrijednosti s kvadratnim korijenom prosječnog broja radnih dana u mjesecu u SAD-u (21). Pri jednakom uloženom iznosu u najrizičniju dionicu portfelja, maksimalni gubitak pri razini od 95% iznosio bi 18 021,77 kn na mjesečnoj razini, dok bi pri razini pouzdanosti od 99% maksimalni mjesečni gubitak iznosio 32 268,00 kn. Najsigurnija dionica pri razini pouzdanosti od 95% u promatranom razdoblju je dionica Johnson & Johnson s maksimalnim potencijalnim gubicima od 1,4% uloga, dok je pri razini od 99% najsigurnija dionica Procter & Gamble Co. s gubitkom od 2,30% uloga.

Tablica 6. VaR odabranih dionica nakon predsjedničkih izbora

DIONICE	ULOG	DNEVNI VaR				MJESEČNI VaR	
	(KN)	VaR 95%	VaR 99%	VaR 95% (KN)	VaR 99% (KN)	VaR 95% (KN)	VaR 99% (KN)
LYONDELLBASELL	100 000	-2.18%	-3.38%	-2183.22	-3375.47	-10004.75	-15468.36
WESTROCK	100 000	-2.24%	-3.42%	-2236.18	-3423.19	-10247.45	-15687.02
GENERAL MOTORS	100 000	-2.02%	-3.58%	-2020.09	-3582.43	-9257.20	-16416.76
WALT DISNEY	100 000	-1.47%	-3.14%	-1474.92	-3141.85	-6758.94	-14397.78
COCA COLA	100 000	-0.90%	-1.89%	-901.44	-1888.28	-4130.92	-8653.20
PROCTER & GAMBLE	100 000	-0.97%	-2.22%	-974.95	-2216.16	-4467.77	-10155.72
CHEVRON	100 000	-1.59%	-2.51%	-1588.46	-2505.69	-7279.24	-11482.50
EXXON	100 000	-1.49%	-1.91%	-1488.85	-1912.37	-6822.77	-8763.58
CATERPILLAR	100 000	-1.93%	-3.22%	-1932.73	-3224.20	-8856.87	-14775.16
FEDEX	100 000	-1.50%	-3.43%	-1495.06	-3430.22	-6851.22	-15719.23
JP MORGAN CHASE	100 000	-1.50%	-3.28%	-1496.26	-3282.79	-6856.73	-15043.62
CITIGROUP	100 000	-1.75%	-3.02%	-1745.49	-3015.26	-7998.85	-13817.65
JOHNSON & JOHNSON	100 000	-1.03%	-1.93%	-1025.16	-1926.34	-4697.87	-8827.58
CVS HEALTH	100 000	-2.83%	-4.49%	-2830.33	-4492.66	-12970.18	-20587.95
APPLE	100 000	-1.42%	-3.46%	-1416.62	-3460.72	-6491.75	-15859.02
MICROSOFT	100 000	-1.29%	-2.07%	-1290.48	-2071.13	-5913.74	-9491.09
AT&T	100 000	-1.67%	-3.52%	-1665.67	-3524.21	-7633.04	-16149.94
VERIZON	100 000	-1.53%	-3.26%	-1530.24	-3258.23	-7012.43	-14931.07
NEXTERA ENERGY	100 000	-1.16%	-2.40%	-1156.58	-2403.57	-5300.12	-11014.53
AMERICAN WATER WORKS	100 000	-1.61%	-2.79%	-1609.81	-2790.09	-7377.08	-12785.82

Izvor: Izračun autora

Rezultati testiranja rizične vrijednosti u razdoblju od 1 godine nakon predsjedničkih izbora pokazuju da je dionica CVS Health Corp. najrizičnija dionica unutar promatranog portfelja kod obe razine pouzdanosti. Uz razinu pouzdanosti od 95%, maksimalni potencijalni gubici spomenute dionice iznose 2,83% uloga, dok kod razine pouzdanosti od 99% potencijalni gubici iznose 4,49% uložene vrijednosti. Ukoliko distribucija prinosa ostane nepromijenjena, investitor na uloženi 100 000 kuna, uz razinu pouzdanosti od 95%, maksimalno je u mogućnosti izgubiti iznos od 2 830,33 kn na dnevnoj razini što je ekvivalentno mjesečnom potencijalnom gubitku od 12 970,18 kn. Uz razinu pouzdanosti od 99%, dnevni maksimalni gubitak raste na 4 492,66 kn, odnosno 20 587,95 kn na mjesečnoj razini. Iako se beta koeficijent smanjio u usporedbi s razdobljem prije izbora, rizična vrijednost dionice CVS Health Corp. povećala se u odnosu na prethodno razdoblje ($2,83\% > 2,23\%$; $4,49\% > 3,60\%$). S obzirom da je dionicu CVS Health Corp. karakterizira smanjenje iznosa beta koeficijenta i povećanje rizične vrijednosti u promatranim razdobljima, zaključuje se da se utjecaj sustavnog rizika smanjuje, dok se utjecaj specifičnog rizika na kretanje dnevnih prinosa spomenute dionice povećava tijekom promatranih razdoblja.

Najsigurnija dionica prema rezultatima analize rizične vrijednosti poslije izbora, promatrajući obje razine pouzdanosti, je dionica Coca Cola Co. s maksimalnim potencijalnim gubicima od 0,90% i 1,89% uložene vrijednosti, uz razine pouzdanosti od 95% i 99%. Iako je većina dionica smanjila rizične vrijednosti u razdoblju nakon predsjedničkih izbora, ulaganje u dionice CVS Health Corp. i AT&T Inc. pri obje razine pouzdanosti te dionicu Verizon Communications Inc. uz razinu pouzdanosti od 99%, postalo je riskantnije u odnosu na prethodno razdoblje. Stoga, kao i kod analize beta koeficijenta, nije moguće utvrditi koje je razdoblje sigurnije za ulaganje.

4.3. Efikasna granica u razdoblju prije predsjedničkih izbora u SAD-u

Za potrebe ovog rada preuzeto je 250 dnevnih cijena odabranih 20 dionica u razdoblju 1 godine prije predsjedničkih izbora te su izračunati dnevni prinosi svih dionica u spomenutom razdoblju. Prosječna cijena, prosječan dnevni prinos, standardna devijacija i varijanca dionica prikazani su u sljedećoj tablici.

Tablica 7. Karakteristike odabranih dionica u razdoblju prije predsjedničkih izbora

SEKTOR	IME PODUZEĆA	PROSJEČNA CIJENA DIONICE (\$)	PROSJEČNI DNEVNI PRINOS DIONICE	STANDARDNA DEVIJACIJA	VARIJANCA
BASIC MATERIALS	LYONDELLBASELL	81.70	-0.06%	1.92%	0.037%
	WESTROCK	41.94	-0.01%	2.52%	0.063%
CONSUMER CYCLICALS	GENERAL MOTORS	31.38	-0.04%	1.49%	0.022%
	WALT DISNEY	99.21	-0.09%	1.15%	0.013%
CONSUMER NON-CYCLICALS	COCA COLA	43.76	0.01%	0.91%	0.008%
	PROCTER & GAMBLE	82.76	0.05%	0.92%	0.009%
ENERGY	CHEVRON	96.48	0.06%	1.63%	0.026%
	EXXON	84.87	0.02%	1.33%	0.018%
INDUSTRIALS	CATERPILLAR	75.01	0.07%	1.72%	0.029%
	FEDEX	156.88	0.05%	1.60%	0.026%
FINANCIALS	JP MORGAN CHASE	63.33	0.01%	1.54%	0.024%
	CITIGROUP	45.79	-0.04%	1.99%	0.040%
HEALTHCARE	JOHNSON & JOHNSON	111.76	0.06%	0.85%	0.007%
	CVS HEALTH	95.72	-0.06%	1.22%	0.015%
TECHNOLOGY	APPLE	104.79	-0.03%	1.54%	0.024%
	MICROSOFT	54.28	0.04%	1.44%	0.021%
TELECOMMUNICATIONS	AT&T	38.40	0.05%	0.92%	0.008%
	VERIZON	50.69	0.02%	1.01%	0.010%
UTILITIES	NEXTERA ENERGY	117.17	0.09%	1.08%	0.012%
	AMERICAN WATER WORKS	70.41	0.10%	1.22%	0.015%

Izvor: Izračun autora

Prema prikazanim rezultatima dionica American Water Works Co. Inc. ima najveći prosječni dnevni prinos od 0,10%, dok najveću standardnu devijaciju u portfelju posjeduje Westrock Co. u iznosu od 2,52%. Na temelju prikazanih podataka može se pretpostaviti da će udio dionice s najvećim prinosom rasti s porastom rizika u efikasnom portfelju. Najmanji prinos od svih sastavnica portfelja ima dionica Walt Disney Co. s prinosom od -0,09%, dok dionica Johnson & Johnson ima najmanje prosječno odstupanje vrijednosti od aritmetičke sredine u iznosu od 0,85%.

Izračunavanje efikasne granice portfelja zahtjeva formiranje matrice varijanci i kovarijanci. Varijanca predstavlja kvadratno odstupanje vrijednosti od njezine aritmetičke sredine te se nalazi na dijagonali matrice. Kovarijanca se definira kao suma ponderiranih umnožaka odstupanja od očekivane vrijednosti dvije varijable te predstavlja mjeru korelacije između dionica koje sačinjavaju portfelj. Kovarijanca između prinosa iste dionice je zapravo njena varijanca. Varijance dionica raspoređene su po dijagonali te odvajaju dvije zrcalno simetrične strane matrice. Najveću varijancu među odabranim dionicama ima dionica Westrock Co. te iznosi 0,000632, dok najmanju varijancu od 0,000072 ima dionica Johnson & Johnson. Na slici 16 prikazana je matrica varijanci i kovarijanci odabranog portfelja u razdoblju prije izbora.

MATRICA VARIJANCI I KOVARIJANCI																				
	LYB	WRK	GM	DIS	KO	PG	CVX	XOM	CAT	FDX	JPM	C	JNJ	CVS	AAPL	MSFT	T	VZ	NEE	AWK
LYB	0.000367	0.000067	0.000124	0.000093	0.000047	0.000039	0.000167	0.000129	0.000210	0.000151	0.000162	0.000212	0.000044	0.000045	0.000104	0.000110	0.000037	0.000053	0.000008	-0.000004
WESTROCK	0.000219	0.000632	0.000162	0.000118	0.000055	0.000062	0.000138	0.000107	0.000225	0.000190	0.000200	0.000288	0.000050	0.000057	0.000096	0.000144	0.000049	0.000069	0.000028	0.000035
GM	0.000124	0.000162	0.000222	0.000082	0.000035	0.000038	0.000103	0.000060	0.000139	0.000118	0.000133	0.000184	0.000041	0.000038	0.000084	0.000099	0.000041	0.000043	0.000007	0.000002
W. DISNEY	0.000093	0.000118	0.000082	0.000133	0.000045	0.000044	0.000083	0.000069	0.000096	0.000093	0.000097	0.000130	0.000043	0.000046	0.000070	0.000074	0.000037	0.000041	0.000024	0.000016
COCA COLA	0.000047	0.000055	0.000035	0.000045	0.000083	0.000053	0.000059	0.000044	0.000044	0.000063	0.000055	0.000056	0.000032	0.000043	0.000035	0.000058	0.000043	0.000046	0.000053	0.000052
P&G	0.000039	0.000062	0.000038	0.000044	0.000053	0.000085	0.000062	0.000049	0.000049	0.000057	0.000065	0.000072	0.000042	0.000034	0.000043	0.000055	0.000042	0.000042	0.000042	0.000045
CHEVRON	0.000167	0.000138	0.000103	0.000083	0.000059	0.000062	0.000265	0.000169	0.000167	0.000116	0.000138	0.000156	0.000065	0.000049	0.000079	0.000101	0.000063	0.000070	0.000032	0.000034
EXXON	0.000129	0.000107	0.000060	0.000069	0.000044	0.000049	0.000169	0.000176	0.000125	0.000085	0.000107	0.000123	0.000050	0.000043	0.000059	0.000060	0.000047	0.000054	0.000025	0.000030
CAT	0.000210	0.000225	0.000139	0.000096	0.000044	0.000049	0.000167	0.000125	0.000294	0.000142	0.000154	0.000209	0.000045	0.000050	0.000105	0.000102	0.000052	0.000055	0.000017	0.000010
FEDEX	0.000151	0.000190	0.000118	0.000093	0.000063	0.000057	0.000116	0.000085	0.000142	0.000257	0.000146	0.000192	0.000049	0.000051	0.000082	0.000107	0.000053	0.000060	0.000041	0.000035
JPMORGAN	0.000162	0.000200	0.000133	0.000097	0.000055	0.000065	0.000138	0.000107	0.000154	0.000146	0.000237	0.000282	0.000063	0.000068	0.000110	0.000124	0.000040	0.000052	0.000016	0.000004
CITIGROUP	0.000212	0.000288	0.000184	0.000130	0.000056	0.000072	0.000156	0.000123	0.000209	0.000192	0.000282	0.000396	0.000069	0.000086	0.000138	0.000157	0.000042	0.000056	0.000001	-0.000006
J&J	0.000044	0.000050	0.000041	0.000043	0.000032	0.000042	0.000065	0.000050	0.000045	0.000049	0.000063	0.000069	0.000072	0.000032	0.000039	0.000050	0.000035	0.000039	0.000030	0.000030
CVS	0.000045	0.000057	0.000038	0.000046	0.000043	0.000034	0.000049	0.000043	0.000050	0.000051	0.000068	0.000086	0.000032	0.000148	0.000054	0.000071	0.000034	0.000043	0.000037	0.000040
APPLE	0.000104	0.000096	0.000084	0.000070	0.000035	0.000043	0.000079	0.000059	0.000105	0.000082	0.000110	0.000138	0.000039	0.000054	0.000238	0.000112	0.000039	0.000037	0.000019	0.000025
MICROSOFT	0.000110	0.000144	0.000099	0.000074	0.000058	0.000055	0.000101	0.000060	0.000102	0.000107	0.000124	0.000157	0.000050	0.000071	0.000112	0.000208	0.000040	0.000050	0.000034	0.000044
AT&T	0.000037	0.000049	0.000041	0.000037	0.000043	0.000042	0.000063	0.000047	0.000052	0.000053	0.000040	0.000042	0.000035	0.000034	0.000039	0.000040	0.000085	0.000077	0.000051	0.000052
VERIZON	0.000053	0.000069	0.000043	0.000041	0.000046	0.000042	0.000070	0.000054	0.000055	0.000060	0.000052	0.000056	0.000039	0.000043	0.000037	0.000050	0.000077	0.000102	0.000054	0.000054
NEXTERA	0.000008	0.000028	0.000007	0.000024	0.000053	0.000042	0.000032	0.000025	0.000017	0.000041	0.000016	0.000001	0.000030	0.000037	0.000019	0.000034	0.000051	0.000054	0.000117	0.000089
AWWC	-0.000004	0.000035	0.000002	0.000016	0.000052	0.000045	0.000034	0.000030	0.000010	0.000035	0.000004	-0.000006	0.000030	0.000040	0.000025	0.000044	0.000052	0.000054	0.000089	0.000148

Slika 16. Matrica varijanci i kovarijanci portfelja u razdoblju prije predsjedničkih izbora

Izvor: Izračun autora

U Tablici 8 prikazani su udjeli dionica u portfeljima koji oblikuju efikasnu granicu te pripadajući prinosi, standardne devijacije i Sharpeov omjer.

Tablica 8. Udjeli dionica u portfelju pri različitim razinama rizika prije izbora


UDJELI DIONICA U PORTFELJU										
ST. DEVIJACIJA PORTFELJA	0.68%	0.70%	0.74%	0.80%	0.85%	0.90%	0.98%	1.05%	1.15%	1.22%
PRINOS PORTFELJA	0.03%	0.05%	0.07%	0.08%	0.09%	0.09%	0.09%	0.10%	0.10%	0.10%
SHARPE RATIO	0.04	0.07	0.09	0.10	0.10	0.10	0.10	0.09	0.09	0.08
LYONDELLBASELL	0.53%	0.00%	0.20%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
WESTROCK	0.00%	0.00%	0.21%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
GENERAL MOTORS	4.46%	3.44%	0.15%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
WALT DISNEY	4.38%	0.00%	0.28%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
COCA COLA	12.06%	6.80%	0.20%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
PROCTER & GAMBLE	8.86%	14.38%	9.24%	0.00%	0.00%	0.00%	1.53%	0.00%	0.00%	0.00%
CHEVRON	0.00%	0.00%	0.18%	0.00%	0.00%	0.00%	0.43%	0.00%	0.00%	0.00%
EXXON	0.00%	2.46%	0.28%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
CATERPILLAR	0.00%	4.03%	7.18%	10.97%	12.03%	10.14%	9.08%	0.00%	0.00%	0.00%
FEDEX	0.00%	0.00%	0.15%	0.00%	0.00%	0.00%	0.23%	0.00%	0.00%	0.00%
JP MORGAN CHASE	0.00%	0.00%	0.15%	0.00%	0.00%	0.00%	0.46%	0.00%	0.00%	0.00%
CITIGROUP	0.00%	0.00%	0.35%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
JOHNSON & JOHNSON	30.47%	24.71%	27.19%	29.36%	18.06%	11.09%	0.75%	0.51%	0.00%	0.00%
CVS HEALTH	8.75%	2.91%	0.31%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
APPLE	2.36%	1.80%	0.43%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
MICROSOFT	0.00%	0.07%	0.00%	0.00%	0.00%	0.00%	0.20%	0.00%	0.00%	0.00%
AT&T	14.62%	12.52%	12.78%	0.00%	0.00%	0.00%	0.19%	0.00%	0.00%	0.00%
VERIZON	0.00%	4.14%	0.39%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
NEXTERA ENERGY	9.44%	13.78%	19.60%	32.55%	36.54%	39.68%	33.49%	48.91%	15.11%	0.00%
AMERICAN WATER WORKS	4.08%	8.95%	20.74%	27.12%	33.37%	39.10%	53.59%	50.58%	84.89%	100.00%

Izvor: Izračun autora

Dva najbitnija portfelja u konstruiranju efikasne granice su portfelj s najmanjom mogućom varijancom i portfelj s najvećim iznosom Sharpeovog omjera, te su označeni tamnoplavom bojom. Portfelj minimalne varijance je točka iz koje efikasna granica polazi. U razdoblju prije predsjedničkih izbora u SAD-u dnevni prinos portfelja minimalne varijance iznosi 0,03%, dok standardna devijacija iznosi 0,68%. Sharpeov omjer je omjer prinosa i standardne devijacije portfelja te njegovim maksimiziranjem formiramo optimalni portfelj koji sadrži najveći iznos prinosa po jedinici rizika. Najveći Sharpeov omjer u razdoblju prije izbora je 0,10 sa standardnom devijacijom 0,80% te dnevnim prinosom portfelja od 0,08%.

Pri nižim razinama rizika, optimalni portfelj je sastavljen od većeg broja dionica, dok s povećanjem standardne devijacije broj dionica koje čine portfelj opada te se udio rizičnijih dionica s većim dnevnim prinosima povećava. Najveća standardna devijacija efikasnog portfelja u promatranom razdoblju je 1,22% pri čemu je portfelj formiran od samo jedne najrizičnije vrijednosnice, dionice American Water Works Co. Inc. s dnevnim prinosom od 0,10%.

Korištenjem Excelove funkcije Solver na temelju prethodno izračunatih podataka formira se granica efikasnih portfelja. Efikasna granicu u razdoblju 1 godinu prije predsjedničkih izbora u SAD-u prikazana je na sljedećoj slici.



Slika 17. Efikasna granica portfelja u razdoblju prije predsjedničkih izbora

Izvor: Izračun autora

Efikasna granica prikazuje skup optimalnih portfelja s najvećim prinosom za zadanu razinu rizika ili najmanjim rizikom uz zadanu razinu prinosa. Pozicioniranje investitora duž efikasne granice ovisi o njegovim preferencijama. Ukoliko investitor ne želi preuzimati veliki rizik, njegov će optimalni portfelj biti na lijevoj strani efikasne granice, odnosno bliže portfelju s minimalnom varijansom. U slučaju da investitor preferira veće prinose bez obzira na rizik, njegov optimalni portfelj bit će smješten na desnoj strani efikasne granice, u blizini portfelja s najvećom mogućom varijansom.

Efikasna granica u razdoblju 1 godine prije predsjedničkih izbora ima raspon rizika od minimalne standardne devijacije u iznosu od 0,68% do maksimalne u iznosu od 1,22%. Portfelj minimalne varijance sastavljen je od dionica 11 različitih poduzeća te prinos spomenutog portfelja iznosi 0,03%. Najrizičniji portfelj efikasne granice ima prinos od 0,10% na dnevnoj razini te je sačinjen od stopostotnog udjela dionice American Water Works Co. Inc. To je ujedno i maksimalan dnevni prinos koji investitor može ostvariti na osnovi analize efikasne granice u promatranom razdoblju.

4.4. Efikasna granica u razdoblju nakon predsjedničkih izbora u SAD-u

Iste dionice koje su promatrane u razdoblju prije izbora, testirane su i nakon izbora u jednakom vremenskom periodu (1 godina). Na temelju 250 dnevnih cijena istih 20 dionica izračunati su prosječni dnevni prinosi, standardna devijacija i varijanca dionica te su prikazani u tablici 9.

Tablica 9. Karakteristike odabranih dionica u razdoblju nakon predsjedničkih izbora

SEKTOR	IME PODUZEĆA	PROSJEČNA CIJENA DIONICE (\$)	PROSJEČNI DNEVNI PRINOS DIONICE	STANDARDNA DEVIJACIJA	VARIJANCA
BASIC MATERIALS	LYONDELLBASELL	89.48	0.10%	1.39%	0.019%
	WESTROCK	54.83	0.08%	1.25%	0.016%
CONSUMER CYCLICALS	GENERAL MOTORS	36.62	0.11%	1.41%	0.020%
	WALT DISNEY	105.75	0.03%	0.87%	0.008%
CONSUMER NON-CYCLICALS	COCA COLA	43.74	0.05%	0.60%	0.004%
	PROCTER & GAMBLE	88.58	0.03%	0.69%	0.005%
ENERGY	CHEVRON	110.74	0.04%	0.91%	0.008%
	EXXON	82.65	-0.01%	0.76%	0.006%
INDUSTRIALS	CATERPILLAR	106.05	0.16%	1.28%	0.016%
	FEDEX	202.11	0.07%	1.02%	0.010%
FINANCIALS	JP MORGAN CHASE	89.28	0.09%	1.00%	0.010%
	CITIGROUP	63.58	0.12%	1.13%	0.013%
HEALTHCARE	JOHNSON & JOHNSON	126.38	0.07%	0.75%	0.006%
	CVS HEALTH	78.34	-0.02%	1.28%	0.016%
TECHNOLOGY	APPLE	142.78	0.21%	1.09%	0.012%
	MICROSOFT	68.98	0.15%	0.91%	0.008%
TELECOMMUNICATIONS	AT&T	39.05	-0.02%	1.07%	0.011%
	VERIZON	48.35	-0.01%	1.08%	0.012%
UTILITIES	NEXTERA ENERGY	135.65	0.12%	0.77%	0.006%
	AMERICAN WATER WORKS	78.28	0.10%	0.90%	0.008%

Izvor: Izračun autora

Najveći prosječni dnevni prinos među sektorima u razdoblju 1 godine nakon predsjedničkih izbora imaju dionice tehnološkog sektora. Dionica Apple Inc. s prosječnim dnevnim prinosom od 0,21% najprofitabilnija je dionica u promatranom razdoblju. Pretpostavlja se da bi udio dionice s najvećim prinosom u efikasnom portfelju trebao rasti s povećanjem rizika do maksimalnih 1,09% koliko iznosi vrijednost standardne devijacije spomenute dionice. Najveći rizik sadrži dionica General Motors Co. sa standardnom devijacijom od 1,41%, dok najmanju standardnu devijaciju ima dionica Coca Cola Co. u iznosu od 0,60%.

Za izračunavanje efikasne granice potrebno je formirati matricu varijanci i kovarijanci u razdoblju od 1 godine nakon predsjedničkih izbora u SAD-u. Varijance odabranih dionica raspoređene su po dijagonali. Najmanju varijancu u promatranom razdoblju ima dionica Coca Cola Co. u iznosu od 0,000036, dok najveću varijancu od 0,000198 ima dionica General Motors Co. Matrica varijanci i kovarijanci u razdoblju nakon izbora prikazana je na sljedećoj slici.

MATRICA VARIJANCI I KOVARIJANCI																				
	LYB	WRK	GM	DIS	KO	PG	CVX	XOM	CAT	FDX	JPM	C	JNJ	CVS	AAPL	MSFT	T	VZ	NEE	AWK
LYB	0.000192	0.000004	0.000055	0.000017	-0.000006	0.000005	0.000053	0.000031	0.000064	0.000045	0.000052	0.000057	-0.000001	0.000015	0.000021	0.000007	0.000007	-0.000002	-0.000017	-0.000008
WESTROCK	0.000045	0.000154	0.000051	0.000019	0.000011	0.000008	0.000020	0.000016	0.000044	0.000044	0.000049	0.000054	0.000000	0.000005	0.000029	0.000024	0.000011	0.000009	0.000004	0.000006
GM	0.000055	0.000051	0.000198	0.000033	0.000008	0.000006	0.000030	0.000018	0.000048	0.000030	0.000048	0.000061	0.000002	0.000030	0.000010	0.000006	0.000032	0.000025	-0.000003	0.000005
W. DISNEY	0.000017	0.000019	0.000033	0.000076	0.000004	0.000006	0.000004	0.000006	0.000012	0.000006	0.000017	0.000021	-0.000002	0.000014	0.000006	0.000008	0.000032	0.000024	-0.000001	0.000000
COCA COLA	-0.000006	0.000011	0.000008	0.000004	0.000036	0.000017	0.000006	0.000006	0.000003	0.000004	-0.000004	-0.000005	0.000005	0.000014	0.000003	0.000006	0.000017	0.000016	0.000016	0.000019
P&G	0.000005	0.000008	0.000006	0.000006	0.000017	0.000048	0.000009	0.000012	0.000014	0.000005	-0.000002	-0.000001	0.000010	0.000008	0.000004	0.000005	0.000014	0.000015	0.000012	0.000019
CHEVRON	0.000053	0.000020	0.000030	0.000004	0.000006	0.000009	0.000083	0.000042	0.000035	0.000014	0.000029	0.000034	0.000004	0.000013	-0.000002	-0.000008	0.000018	0.000016	-0.000004	0.000011
EXXON	0.000031	0.000016	0.000018	0.000006	0.000006	0.000012	0.000042	0.000058	0.000029	0.000018	0.000021	0.000027	0.000010	0.000003	0.000005	0.000007	0.000015	0.000014	-0.000001	0.000009
CATERPILLAR	0.000064	0.000044	0.000048	0.000012	0.000003	0.000014	0.000035	0.000029	0.000165	0.000051	0.000052	0.000056	-0.000001	0.000020	0.000019	0.000027	0.000013	0.000012	-0.000004	-0.000001
FEDEX	0.000045	0.000044	0.000030	0.000006	0.000004	0.000005	0.000014	0.000018	0.000051	0.000103	0.000040	0.000042	0.000010	0.000022	0.000023	0.000038	0.000005	0.000002	0.000006	0.000009
JPMORGAN	0.000052	0.000049	0.000048	0.000017	-0.000004	-0.000002	0.000029	0.000021	0.000052	0.000040	0.000100	0.000092	0.000002	0.000016	0.000021	0.000018	0.000014	0.000008	-0.000023	-0.000018
CITIGROUP	0.000057	0.000054	0.000061	0.000021	-0.000005	-0.000001	0.000034	0.000027	0.000056	0.000042	0.000092	0.000128	0.000004	0.000017	0.000023	0.000020	0.000021	0.000010	-0.000026	-0.000018
J&J	-0.000001	0.000000	0.000002	-0.000002	0.000005	0.000010	0.000004	0.000010	-0.000001	0.000010	0.000002	0.000004	0.000056	0.000005	0.000003	0.000011	0.000007	0.000014	0.000013	0.000015
CVS	0.000015	0.000005	0.000030	0.000014	0.000014	0.000008	0.000013	0.000003	0.000020	0.000022	0.000016	0.000017	0.000005	0.000163	-0.000001	-0.000007	0.000017	0.000022	-0.000002	-0.000002
APPLE	0.000021	0.000029	0.000010	0.000006	0.000003	0.000004	-0.000002	0.000005	0.000019	0.000023	0.000021	0.000023	0.000003	-0.000001	0.000118	0.000045	0.000006	-0.000007	0.000007	0.000001
MICROSOFT	0.000007	0.000024	0.000006	0.000008	0.000006	0.000005	-0.000008	0.000007	0.000027	0.000038	0.000018	0.000020	0.000011	-0.000007	0.000045	0.000083	0.000008	0.000008	0.000013	0.000015
AT&T	0.000007	0.000011	0.000032	0.000032	0.000017	0.000014	0.000018	0.000015	0.000013	0.000005	0.000014	0.000021	0.000007	0.000017	0.000006	0.000008	0.000115	0.000077	0.000014	0.000020
VERIZON	-0.000002	0.000009	0.000025	0.000024	0.000016	0.000015	0.000016	0.000014	0.000012	0.000002	0.000008	0.000010	0.000014	0.000022	-0.000007	0.000008	0.000077	0.000117	0.000014	0.000020
NEXTERA	-0.000017	0.000004	-0.000003	-0.000001	0.000016	0.000012	-0.000004	-0.000001	-0.000004	0.000006	-0.000023	-0.000026	0.000013	-0.000002	0.000007	0.000013	0.000014	0.000014	0.000059	0.000037
AWWC	-0.000008	0.000006	0.000005	0.000000	0.000019	0.000019	0.000011	0.000009	-0.000001	0.000009	-0.000018	-0.000018	0.000015	-0.000002	0.000001	0.000015	0.000020	0.000020	0.000037	0.000082

Slika 18. Matrica varijanci i kovarijanci portfelja u razdoblju nakon predsjedničkih izbora

Izvor: Izračun autora

Matrica varijanci i kovarijanci korištena je kako bi izračunali udjele u portfeljima koji oblikuju efikasnu granicu. Broj dionica koji čine efikasne portfelje smanjuje se s povećanjem standardne devijacije. Udio dionice Apple Inc., koja ima najveći prosječni dnevni prinos u promatranom razdoblju, raste s povećanjem zadane razine rizika efikasnog portfelja, sukladno očekivanjima.

Dva najčešće korištena portfelja na efikasnoj granici su portfelj minimalne varijance i portfelj s najvećim Sharpeovim omjerom te su označeni tamnocrvenom bojom u tablici 10. Portfelj minimalne varijance u razdoblju nakon izbora te ima dnevni prinos od 0,07% i standardnu devijaciju od 0,36%. Portfelj s najvećim Sharpeovim omjerom od 0,29 ima dnevni prinos od 0,13% i standardnu devijaciju od 0,47%. Navedeni portfelji, zajedno s udjelima ostalih portfelja koji čine efikasnu granicu u promatranom razdoblju, prikazani su u sljedećoj tablici.


Tablica 10. Udjeli dionica u portfelju pri različitim razinama rizika nakon izbora

UDJELI DIONICA U PORTFELJU										
ST. DEVIJACIJA PORTFELJA	0.36%	0.38%	0.42%	0.47%	0.55%	0.65%	0.75%	0.85%	0.97%	1.09%
PRINOS PORTFELJA	0.07%	0.09%	0.12%	0.13%	0.15%	0.17%	0.18%	0.19%	0.20%	0.21%
SHARPE RATIO	0.20	0.25	0.28	0.29	0.28	0.26	0.24	0.22	0.20	0.19
LYONDELLBASELL	1.70%	0.98%	3.04%	3.05%	0.20%	0.00%	0.02%	0.00%	0.00%	0.00%
WESTROCK	0.00%	2.56%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
GENERAL MOTORS	0.00%	0.00%	0.75%	1.66%	1.01%	0.00%	0.02%	0.00%	0.00%	0.00%
WALT DISNEY	11.22%	7.34%	3.64%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
COCA COLA	18.95%	16.41%	11.31%	4.06%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
PROCTER & GAMBLE	8.15%	1.21%	0.00%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
CHEVRON	5.12%	4.20%	1.52%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
EXXON	5.72%	0.00%	0.00%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
CATERPILLAR	0.00%	2.42%	5.45%	7.53%	11.35%	22.69%	17.24%	21.50%	5.23%	0.00%
FEDEX	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.01%	0.00%	0.00%	0.00%
JP MORGAN CHASE	9.11%	5.54%	2.57%	0.00%	0.00%	0.00%	0.02%	0.00%	0.00%	0.00%
CITIGROUP	0.00%	4.51%	9.16%	12.12%	13.19%	4.56%	0.02%	0.00%	0.00%	0.00%
JOHNSON & JOHNSON	13.64%	13.58%	12.26%	10.11%	0.49%	0.00%	0.03%	0.00%	0.00%	0.00%
CVS HEALTH	3.19%	2.58%	0.00%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
APPLE	4.55%	10.41%	15.45%	19.97%	28.58%	39.93%	60.03%	67.63%	87.62%	100.00%
MICROSOFT	3.89%	4.20%	5.13%	5.98%	10.00%	8.70%	0.84%	5.85%	0.00%	0.00%
AT&T	0.00%	0.81%	0.00%	0.00%	0.00%	0.00%	0.03%	0.00%	0.00%	0.00%
VERIZON	0.00%	0.37%	0.00%	0.00%	0.00%	0.00%	0.04%	0.00%	0.00%	0.00%
NEXTERA ENERGY	14.48%	21.02%	26.79%	32.18%	32.95%	24.12%	21.48%	5.02%	7.16%	0.00%
AMERICAN WATER WORKS	0.29%	1.86%	2.93%	3.34%	2.23%	0.00%	0.03%	0.00%	0.00%	0.00%

Izvor: Izračun autora

Korištenjem Excelove funkcije Solver na temelju prethodno izračunatih podataka formira se efikasna granica u razdoblju nakon predsjedničkih izbora u SAD-u. Efikasna granica u promatranom razdoblju proteže se od minimalne standardne devijacije u iznosu od 0,36% do maksimalne u iznosu od 1,09%. Portfelj s minimalnom razinom rizika sastoji se od 13 različitih dionica koji u različitim omjerima sudjeluju u formiranju dnevnog prinosa od 0,07%.

Maksimalan dnevni prinos od 0,21% postiže se pri razini rizika od 1,09% te predstavlja prinos najrizičnijeg portfelja na efikasnoj granici. Najrizičniji portfelj sastoji se od stopostotnog udjela dionice Apple Inc. Optimalni portfelj investitora leži na efikasnoj granici te ovisi o razini rizika koju je pojedini investitor spreman prihvatiti. Efikasna granica odabranog portfelja u razdoblju 1 godine nakon predsjedničkih izbora u SAD-u prikazana je na sljedećoj slici.




Slika 19. Efikasna granica portfelja u razdoblju nakon predsjedničkih izbora

Izvor: Izračun autora

4.5. Usporedba dobivenih rezultata

Neočekivana pobjeda republikanskog kandidata Donalda Trumpa na predsjedničkim izborima u Sjedinjenim Američkim Državama uzrokovala je paniku na tržištima kapitala diljem svijeta. Većina analitičara smatrala je da njegova pobjeda znači dugotrajnu ekonomsku nestabilnost i nesigurnost investicijskog okruženja. Formiranjem efikasnih granica u razdobljima od 1 godine prije i nakon predsjedničkih izbora, sastavljenih od portfelja 20 dionica iz 10 jednako zastupljenih sektora, dobiveni su rezultati suprotni očekivanjima analitičara.

Usporedbom efikasnih granica evidentno je da efikasni portfelj u razdoblju nakon pobjede Donalda Trumpa ima veći prinos za jednaku razinu rizika, odnosno manju standardnu devijaciju za jednaku razinu prinosa u odnosu na efikasni portfelj u razdoblju prije predsjedničkih izbora. Usporedba formiranih efikasnih granica prikazana je na sljedećoj slici.



Slika 20. Usporedba efikasnih granica

Izvor: Izračun autora

Na prikazanoj slici, uspoređujući s razdobljem prije izbora, primjetni su značajno veći dnevni prinosi efikasnih portfelja u razdoblju nakon predsjedničkih izbora. Spomenuta tvrdnja može se potvrditi jednostavnom usporedbom dnevnih prinosa efikasnih portfelja u oba promatrana razdoblja pri jednakoj razini rizika, odnosno standardne devijacije. Pri iznosu standardne devijacije od 0,85%, efikasni portfelj u razdoblju prije predsjedničkih izbora ima dnevni prinos u iznosu od 0,09%, dok efikasni portfelj nakon pobjede Donalda Trumpa, pri jednakoj razini rizika, ima prinos od 0,19% na dnevnoj razini. Navedeni rezultati predstavljaju značajno povećanje profitabilnosti vrijednosnica na američkom tržištu kapitala. Dakle, sigurnost i prinos ulaganja povećali su se dolaskom republikanskog kandidata na mjesto predsjednika Sjedinjenih Američkih Država.

5. ZAKLJUČAK

Moderna teorija portfelja, čije je temelje postavio Harry Max Markowitz svojim radom “Portfolio Selection“ iz 1952. godine, je uvođenjem pojma diversifikacije napravila revoluciju u dotadašnjem poimanju efikasnosti portfelja i načinu odabira sastavnica efikasnog portfelja. Markowitzev model omogućava reduciranje razine rizika diversifikacijom portfelja što je najjednostavnije objašnjeno maksimom „nije dobro držati sva jaja u istoj košari“. Markowitz u prvi plan stavlja odnos prinosa i rizika koji uz korelaciju određuju isplativost ulaganja. Model se također naziva i MV model (mean-variance) jer omogućava investitorima da maksimiziraju prinos pri određenoj stopi rizika, odnosno minimiziraju rizik pri određenoj stopi prinosa.

Markowitzev model primijenjen je na američkom tržištu kapitala koji se najčešće poistovjećuje dvije najveće svjetske burze po tržišnoj kapitaliziranosti, NYSE i NASDAQ. Značaj američkog tržišta kapitala u svjetskom financijskom sustavu je očigledan s obzirom da većina najvećih svjetskih korporacija kotira upravo na spomenutim burzama te predstavljaju oko 40% svjetske tržišne kapitalizacije. Stoga događaji koji utječu na američko tržište kapitala, poput izbora za predsjednika SAD-a, imaju snažan utjecaj na cjelokupni svjetski financijski sustav. Neočekivana pobjeda Donalda Trumpa prouzročila je paniku na svjetskim burzama te izazvala zabrinutost analitičara oko budućnosti američke ekonomije.

Opravdanost nepovjerenja investitora i analitičara prema novom američkom predsjedniku testirana je formiranjem efikasnih granica diversificiranog portfelja na američkom tržištu kapitala. Odabran je portfelj od 20 dionica velike tržišne kapitalizacije koje kotiraju na američkim burzama. Zbog reprezentativnosti uzorka odabrane su dionice poduzeća iz 10 jednako zastupljenih sektora prema Thomas Reuters klasifikaciji poduzeća. Analizirani su prinosi na temelju cijena dionica na dnevnoj razini u razdoblju od 1 godine prije, te u razdoblju 1 godine nakon predsjedničkih izbora u Sjedinjenim Američkim Državama. Cilj istraživanja ostvaren je usporedbom formiranih efikasnih granica iz promatranih razdoblja i izračuna mjera rizika dionica, čime su dobiveni rezultati postavljenih hipoteza s početka diplomskog rada. Hipoteze se odnose na povećanje prinosa i smanjenje rizika portfelja na američkom tržištu kapitala te na negativan utjecaj rezultata predsjedničkih izbora na ostala svjetska tržišta kapitala.

Provedena analiza efikasnih granica portfelja rezultirala je značajnim povećanjem dnevnih prinosa u razdoblju nakon predsjedničkih izbora u odnosu na jednak vremenski period u razdoblju prije izbora. Na temelju dobivenih rezultata prihvaća se prva hipoteza da prinos koji portfelj nosi investitoru na američkom tržištu kapitala, uz zadanu stopu rizika, značajno raste nakon izbora Donalda Trumpa za predsjednika SAD-a.

Analiza beta koeficijenta i rizične vrijednosti rezultirala je kontradiktornim podacima. Iako se beta koeficijent jednako ponderiranog portfelja smanjio u razdoblju nakon izbora, beta koeficijenti dionice General Motors Co. te dionica iz telekomunikacijskog, tehnološkog i industrijskog sektora povećavaju se u usporedbi s razdobljem prije izbora. Slični rezultati dobiveni su i analizom VaR-a. Dok je većina dionica smanjila rizične vrijednosti nakon izbora, maksimalan mogući gubitak povećan je kod dionica CVS Health Corp. i AT&T Inc. pri obe razine pouzdanosti te dionice Verizon Communications Inc. uz razinu pouzdanosti od 99%. Stoga, na temelju provedene analize ne može se prihvatiti druga hipoteza koja pretpostavlja da rizik dionica s američkog tržišta kapitala značajno pada nakon rezultata predsjedničkih izbora.

Također, istraživanje je obuhvatilo utjecaj izbora Donalda Trumpa za predsjednika SAD-a na ostala svjetska tržišta kapitala. Rezultati izbora iznenadili su investitore diljem svijeta te doveli do naglog pada burzovnih indeksa. Međutim, ohrabreni reakcijom investitora na američkom tržištu kapitala, svjetski burzovni indeksi vrlo brzo su se oporavili u potpunosti. Činjenicu da neočekivani rasplet predsjedničkih izbora u SAD-u nije ostavio dugotrajne posljedice na svjetska tržišta kapitala potkrepljuju prinosi kineskih (45%), indijskih (41%) i europskih (15%) dionica u 2017. godini. Dakle, na temelju kretanja burzovnih indeksa i istraživanja analitičara, posljednja hipoteza o negativnom utjecaju predsjedničkih izbora na svjetska tržišta kapitala se ne prihvaća.

Na temelju provedene analize utjecaja rezultata izbora za predsjednika SAD-a na tržište kapitala izveden je zaključak u suprotnosti sa predviđanjem ekonomskih analitičara. Strah i zabrinutost analitičara zbog izbora novog američkog predsjednika pokazali su se neutemeljenim. Prosječni prinosi na dionice značajno su porasli, dok su najznačajniji burzovni indeksi dosegli najviše vrijednosti u povijesti. Ohrabrujuća činjenica je brza reakcija investitora koji su se usredotočili na fundamentalne vrijednosti poduzeća te anulirali kratkoročni pad dionica uzrokovan iznenađujućim raspletom izbora. Uspoređujući s prošlim neočekivanim događajima, primjetna je veća otpornost tržišta na izvanredne situacije što povećava sigurnost ulaganja i predstavlja temelj za optimističan pogled na budućnost globalnog financijskog sustava.

SAŽETAK

Neočekivana pobjeda republikanskog kandidata Donalda Trumpa na predsjedničkim izborima u Sjedinjenim Američkim Državama prouzrokovala je paniku na svjetskim tržištima kapitala. Većina ekonomskih analitičara smatrala je da će odluka građana o novom predsjedniku najmoćnije svjetske države izazvati dugoročnu ekonomsku nestabilnost i nesigurnost financijskog sustava.

Cilj ovog diplomskog rada je ispitati točnost predviđanja ekonomskih analitičara primjenom moderne teorije portfelja na američkom tržištu kapitala. Odabran je portfelj od 20 američkih dionica velike tržišne kapitalizacije iz 10 jednako zastupljenih sektora klasificiranim prema Thomas Reuters klasifikaciji poduzeća. Na temelju dnevnih prinosa odabranih dionica formirane su efikasne granice portfelja u razdoblju 1 godine prije izbora te u razdoblju 1 godine nakon predsjedničkih izbora u SAD-u, isključujući tjedan u kojem su održani izbori. Usporedbom formiranih efikasnih granica portfelja opovrgnuta su predviđanja analitičara te je dokazan pozitivan učinak rezultata izbora za predsjednika na investicijske prinose.

Cilj provedene analize je, također, ispitivanje razine rizika dionica u promatranim razdobljima na temelju izračuna beta koeficijenta te iznosa rizične vrijednosti. Rezultati ispitivanja razine rizika nisu pokazali identična kretanja rizika svih dionica stoga se ne može sa sigurnošću utvrditi koje je razdoblje sigurnije za ulaganje.

Analiziran je i utjecaj izbora za predsjednika SAD-a na ostala svjetska tržišta kapitala. Pretpostavljen negativan utjecaj pobjede Donalda Trumpa na predsjedničkim izborima opovrgnut je na temelju istraživanja analitičara i kretanjem svjetskih burzovnih indeksa.

KLJUČNE RIJEČI: Moderna teorija portfelja, Donald Trump, tržište kapitala

SUMMARY

The unexpected victory of Republican candidate Donald Trump during the 2016 presidential elections in the United States of America caused panic across the global capital markets. The majority of economic analysts forecasted that this choice of president of the world's most powerful country would generate long-term economic instability and investment uncertainty.

The aim of this dissertation is to investigate the predictions of economic analysts by using modern portfolio theory on the U.S. stock market. A portfolio compiled of 20 U.S. stocks with large market capitalization was selected. Each of the 10 sectors classified by Thomas Reuters Business Classification is equally represented in the portfolio. Based on daily returns of the chosen stocks, efficient frontiers have been created for two periods: 1 year before and 1 year after presidential elections, excluding the week in which the elections were held. After comparing two efficient frontiers, the prediction of economic analysts is refuted and the positive impact of presidential elections on investment returns is proved.

The aim of the analysis is to examine the risk level of stocks in observed periods by estimating beta and the Value at Risk coefficient. Results of the risk level analysis did not show identical risk movements on all stocks, hence it cannot be determined with total accuracy which period is safer for investing.

The impact of the United States presidential elections on the rest of the world's capital markets is also analysed. The assumed negative impact of Donald Trump's victory on the presidential elections is refuted based on research by analysts and trends in world market indices.

KEYWORDS: Modern portfolio theory, Donald Trump, capital market

POPIS LITERATURE

Knjige

1. Aljinović, Z., Marasović, B. (2012): Matematički modeli u analizi razvoja hrvatskog financijskog tržišta, Sveučilište u Splitu, Ekonomski fakultet Split, Split
2. Aljinović, Z., Marasović, B., Šego, B. (2011): Financijsko modeliranje, Sveučilište u Splitu, Ekonomski fakultet Split, Split
3. Badie, B., Berg-Schlosser, D., Morlino, L. (2011): International Encyclopedia of Political Science, Sage Publications Inc., Los Angeles
4. Baković, T., Brizar, B., Lazibat, T. (2007): Burzovno poslovanje – Terminska trgovina, Znanstvena knjiga, Zagreb
5. Bodie, Z., Kane, A., Marcus, A. (2014): Investments, McGraw-Hill Education Ltd, New York
6. Elton, E.J., Gruber, M.J., Brown, S.J., Goetzmann, W.N. (2007): Modern portfolio theory and investment analysis 7th edition, John Wiley and Sons, Inc., New Jersey
7. Foley, B. (1991): Capital markets, Macmillan Education Ltd, London
8. Jakšić, S. (2007): Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, Zagreb
9. Koch, T.W., MacDonald, S.S. (2000): Bank management, 4th edition, The Dryden Press, Orlando
10. Markowitz, H. (1959): Portfolio Selection: Efficient Diversification of Investments, John Wiley & Sons Inc., New York
11. Orsag, S., Dedi, L. (2014): Tržište kapitala, Alka script, Zagreb
12. Šošić, I., Serdar, V. (1994): Uvod u statistiku, Školska knjiga, Zagreb
13. Tomić-Plazibat, N., Aljinović, Z., Marasović, B. (2006): Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet Split, Split
14. Van Horn, J.C. (1993): Financijsko upravljanje i politika, Mate, Zagreb
15. Žiković, S. (2005): Formiranje optimalnog portfolija hrvatskih dionica i mjerenje tržišnog rizika primjenom VaR metode, Sveučilište u Ljubljani, Ekonomski fakultet Ljubljana, Ljubljana

Znanstvene publikacije

1. Cohen, K.J., Pogue, J.A. (1967): An empirical evaluation of alternative portfolio-selection models, The Journal of Business, 40 (2), 166-193, [Internet], raspoloživo na: http://www.stat.ucla.edu/~nchristo/statistics417/multi_index_diagonal_form.pdf
2. Doidge, C., Kahle, K., Karolyi, G.A., Stulz, R.M. (2018): Eclipse of the public corporation or eclipse of the public markets, European Corporate Governance Institute, [Internet], raspoloživo na: http://ecgi.global/sites/default/files/working_papers/documents/finaldoidgekahlekarolyistulz.pdf
3. Jerončić, M., Aljinović, Z. (2011): Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija, Stručni članak, Ekonomski pregled 62 (9-10), 583-606, [Internet], raspoloživo na: [file:///C:/Users/KORISNIK/Downloads/jeronic%20\(2\).pdf](file:///C:/Users/KORISNIK/Downloads/jeronic%20(2).pdf)
4. Kahneman, D., Tversky, A. (1979.): Prospect theory: An analysis of decisions under risk, Econometrica, 47 (2), 263-292, [Internet] raspoloživo na: <http://people.hss.caltech.edu/~camerer/EC101/ProspectTheory.pdf>
5. Kunovac, D. (2010): Asimetrične korelacije na tržištu kapitala u Hrvatskoj, Institut za javne financije, 35 (1), 1-24, [Internet], raspoloživo na: <http://www.ijf.hr/OP/7.pdf>
6. Latković, M. (2001): Nesinhrono trgovanje i proračun sistematskog rizika, Agencija za nadzor mirovinskih fondova i osiguranja, Zagreb, [Internet], raspoloživo na: <http://www.phy.pmf.unizg.hr/~laci/art/beta.pdf>
7. Morić-Milovanović, B., Ćurković, M. (2014): Utjecaj svjetske financijske krize na formiranje multisektorski-diverzificiranih optimalnih portfelja uz pomoć Markowitzeve teorije na Zagrebačkoj burzi, Ekonomska misao, 23 (1), 389-408, [Internet], raspoloživo na: [file:///C:/Users/KORISNIK/Downloads/26_Moric_Milovanovic_Curkovic%20\(1\).pdf](file:///C:/Users/KORISNIK/Downloads/26_Moric_Milovanovic_Curkovic%20(1).pdf)
8. Orlović, M. (2009): Efikasna diversifikacija, Istraživači rad, Financijski klub, [Internet], raspoloživo na: <http://finance.hr/wp-content/uploads/2009/11/omed.pdf>
9. Radović, M., Vasiljević, A. (2012): Stabilnost beta koeficijenta za najlikvidnije dionice na tržištu kapitala u Srbiji u periodu 2006.-2011. godina, Ekonomske teme, 50 (3), 415-432, [Internet] raspoloživo na: <https://www.ebsco.com/products/research-databases/business-source-premier>

10. Šverko, I. (2001): Moguća primjena povijesne metode rizične vrijednosti pri upravljanju rizicima financijskih institucija u Hrvatskoj, Financijska teorija i praksa, 25 (4), 605-618 [Internet], raspoloživo na: <file:///C:/Users/KORISNIK/Downloads/sverko.pdf>
11. Šverko, I. (2002): Rizična vrijednost (Value at Risk) kao metoda upravljanja rizicima u financijskim institucijama, Ekonomski pregled, 53 (7-8), 640-657, [Internet], raspoloživo na: [file:///C:/Users/KORISNIK/Downloads/03sverko%20\(1\).pdf](file:///C:/Users/KORISNIK/Downloads/03sverko%20(1).pdf)

Internet izvori

1. Allison, B., Harris, B., Rojanasakul, M., Sam, C. (2016): Tracking the 2016 Presidential Money Race, Bloomberg Politics, [Internet], raspoloživo na: <https://www.bloomberg.com/politics/graphics/2016-presidential-campaign-fundraising/>
2. BBC News (2016): US elections 2016: Markets meltdown fails to materialise, BBC News, [Internet], raspoloživo na: <http://www.bbc.co.uk/news/business-37921036>
3. Bourbon, C. (2018): 2017 Stock market returns ring the bell of caution, Morningstar, [Internet], raspoloživo na: <http://www.morningstar.co.uk/uk/news/164153/2017-stock-market-returns-ring-the-bell-of-caution.aspx>
4. Confessore, N., Yourish, K. (2016): \$2 Billion worth of free media for Donald Trump, The New York Times, [Internet], raspoloživo na: https://www.nytimes.com/2016/03/16/upshot/measuring-donald-trumps-mammoth-advantage-in-free-media.html?_r=0
5. Denyer, S., Mui, Y.Q. (2016): Markets staggered by Trump's shock victory but stage partial recovery, The Washington Post, [Internet], raspoloživo na: https://www.washingtonpost.com/world/markets-staggered-by-trumps-shock-victory-but-stage-partial-recovery/2016/11/09/96dfb79e-a659-11e6-9bd6-184ab22d218e_story.html?utm_term=.793ac2af356d
6. Desjardins, J. (2016): All the world stock exchanges by size, The Money Project, [Internet], raspoloživo na: <http://money.visualcapitalist.com/all-of-the-worlds-stock-exchanges-by-size/>
7. Encyclopedia Britannica (2017): Wall Street, Encyclopedia Britannica, [Internet], raspoloživo na: <https://www.britannica.com/topic/Wall-Street-New-York-City>
8. Gara, A. (2016): Global market plunge as Republican Donald Trump gains a path to U.S. presidency, The Forbes, [Internet], raspoloživo na:

- <https://www.forbes.com/sites/antoinegara/2016/11/09/global-markets-plunge-as-republican-donald-trump-gains-a-path-to-u-s-presidency/#7cb1f99c53e1>
9. Golding, B. (2016): Stock market quivers as Trump makes surprise election gains, The New York Post [Internet], raspoloživo na: <https://nypost.com/2016/11/08/stock-market-quivers-as-trump-makes-surprise-election-gains/>
 10. Investopedia (2017): Donald J. Trump, Investopedia, [Internet], raspoloživo na: <https://www.investopedia.com/trump/>
 11. Kralj, I. (2016): Što smo mogli naučiti tržištima iz sumanutih burzovnih reakcija na Trumpovu pobjedu, Telegram, [Internet], raspoloživo na: <https://www.telegram.hr/biznis-tech/sto-smo-iz-mogli-nauciti-o-trzistima-iz-sumanutih-burzovnih-reakcija-na-trumpovu-pobjedu/>
 12. New York Stock Exchange (2017): NYSE Database, NYSE [Internet], raspoloživo na: http://www.nyxdata.com/nysedata/asp/factbook/viewer_edition.asp?mode=table&key=2169&category=4
 13. Reuters Staff (2016): European shares surge in sharp reversal after Trump win, Reuters, [Internet], raspoloživo na: <https://www.reuters.com/article/europe-stocks/european-shares-surge-in-sharp-reversal-after-trump-win-idUSL8N1DA88M>
 14. Schwartzman, P., Johnson, J. (2015): It's not chaos. It's Trump's campaign strategy., The Washington Post, [Internet], raspoloživo na: https://www.washingtonpost.com/politics/its-not-chaos-its-trumps-campaign-strategy/2015/12/09/9005a5be-9d68-11e5-8728-1af6af208198_story.html
 15. The New York Times (2016): Election results, The New York Times [Internet], raspoloživo na: <https://www.nytimes.com/elections/results/president>
 16. Thuy, O. (2016): Market soars as investors take heart after Trump victory speech, Shanghai Daily, [Internet], raspoloživo na: <https://www.shine.cn/archive/AustraliaPlus/Market-soars-as-investors-take-heart-after-Trump-victory-speech/shdaily.shtml>
 17. Wharton Research Data Services (2018): The Center for Research in Security Prices (CRSP), University of Pennsylvania, [Internet], raspoloživo na: https://wrds-web.wharton.upenn.edu/wrds/ds/crsp/stock_a/dsf.cfm?navId=128
 18. World Federation of Exchanges (2017): WFE Annual statistics guide 2016, WFE [Internet], raspoloživo na: <https://www.world-exchanges.org/home/index.php/statistics/annual-statistics>

POPIS SLIKA

Slika 1. Funkcija korisnosti investitora koji izbjegava rizik

Slika 2. Funkcija korisnosti 3 vrste investitora prema stupnju sklonosti riziku

Slika 3. Skup mogućih portfelja

Slika 4. (a) skup minimalne varijance (b) efikasna granica

Slika 5. Primjer efikasnog i neefikasnog portfelja

Slika 6. Sustavni i nesustavni rizik

Slika 7. Metoda rizične vrijednosti

Slika 8. Modeli izračuna rizične vrijednosti

Slika 9. Vrste financijskih instrumenata

Slika 10. Struktura tržišta kapitala

Slika 11. Slogani kandidata na predsjedničkim izborima u SAD-u u 2016. godini

Slika 12. Rezultati predsjedničkih izbora u SAD-u 2016. godine

Slika 13. Rezultati predsjedničkih izbora prema različitim parametrima

Slika 14. Korelacija odabranih dionica u razdoblju prije predsjedničkih izbora

Slika 15. Korelacija odabranih dionica u razdoblju nakon predsjedničkih izbora

Slika 16. Matrica varijanci i kovarijanci portfelja u razdoblju prije predsjedničkih izbora

Slika 17. Efikasna granica portfelja u razdoblju prije predsjedničkih izbora

Slika 18. Matrica varijanci i kovarijanci portfelja u razdoblju nakon predsjedničkih izbora

Slika 19. Efikasna granica portfelja u razdoblju nakon predsjedničkih izbora

Slika 20. Usporedba efikasnih granica

POPIS TABLICA

Tablica 1. Tržišna kapitalizacija NYSE u 2015. i 2016. godini

Tablica 2. Odabrane dionice s Wall Street-a po sektorima

Tablica 3. Beta koeficijent za portfelj prije predsjedničkih izbora

Tablica 4. Beta koeficijent za portfelj poslije predsjedničkih izbora

Tablica 5. VaR odabranih dionica prije predsjedničkih izbora

Tablica 6. VaR odabranih dionica nakon predsjedničkih izbora

Tablica 7. Karakteristike odabranih dionica u razdoblju prije predsjedničkih izbora

Tablica 8. Udjeli dionica u portfelju pri različitim razinama rizika prije izbora

Tablica 9. Karakteristike odabranih dionica u razdoblju nakon predsjedničkih izbora

Tablica 10. Udjeli dionica u portfelju pri različitim razinama rizika nakon izbora